

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU  
**PREHRAMBENO - TEHNOLOŠKI FAKULTET OSIJEK**

Tena Balen

**MATEMATIČKO MODELIRANJE KINETIKE PROMJENE BOJE ČAJNOG  
PECIVA S DODATKOM TROPA GROŽĐA SORTE CABERNET SAUVIGNON**

DIPLOMSKI RAD

Osijek, travanj 2019.

## TEMELJNA DOKUMENTACIJSKA KARTICA

## DIPLOMSKI RAD

Sveučilište Josipa Jurja Strossmayera u Osijeku Prehrambeno-tehnološki fakultet Osijek

Zavod za prehrambene tehnologije

Katedra za tehnologije prerade žitarica

Franje Kuhača 20, 31000 Osijek, Hrvatska

Diplomski sveučilišni studij Prehrambeno inženjerstvo

Znanstveno područje: Biotehničke znanosti

Znanstveno polje: Prehrambena tehnologija

Nastavni predmet: Tehnologija proizvodnje i prerade brašna

**Tema rada** je prihvaćena na X. redovitoj sjednici Fakultetskog vijeća Prehrambeno-tehnološkog fakulteta Osijek u akademskoj godini 2018./2019., održanoj 4. srpnja 2018.

**Mentor:** prof. dr. sc. *Daliborka Koceva Komlenić*

**Komentor:** izv. prof. dr. sc. *Jasmina Lukinac Čačić*

**Pomoć pri izradi:** izv. prof. dr. sc. *Marko Jukić*

### Matematičko modeliranje kinetike promjene boje čajnog peciva s dodatkom tropa grožđa sorte

**Cabernet Sauvignon**

*Tena Balen, 412-DI*

#### Sažetak:

U radu je provedeno matematičko modeliranje kinetike promjene boje čajnog peciva tijekom pečenja s ciljem određivanja parametara kinetičkih modela te predviđanja promjene boje tijekom pečenja i određivanje optimalnih procesnih uvjeta. Uzorci čajnog peciva proizvedeni su u laboratorijskim uvjetima od pšeničnog brašna T-550 te s dodatkom tropa grožđa sorte Cabernet Sauvignon u različitim udjelima (10, 20 i 30%). Za potrebe matematičkog modeliranja te određivanje kinetičkih parametara, mjereni parametri boje izraženi su kao ukupna promjena boje ( $\Delta E$ ), indeks posmeđivanja (BI), indeks gubitka svjetline (100-L), indeks saturacije (SI), indeks tamnjenja (DI) te indeks boje pečenja (BCI). Boja uzoraka mjerena je računalnom analizom slike, a rezultati prikazani u CIEL  $a^*b^*$  sustavu boje. Uspješnost aproksimacije eksperimentalnih podataka kinetičkim modelima procijenjena je pomoću statističkih kriterija  $R^2$  i RMSE. Prema dobivenim rezultatima testiranja matematičkih modela, logistički sinusoidalni model pokazao se kao najprikladniji za predviđanje promjene boje svih analiziranih uzoraka čajnog peciva za sve ispitivane nezavisne varijable modela ( $\Delta E$ , BI, 100-L, SI, DI i BCI).

**Ključne riječi:** čajno pecivo, trop sorte grožđa Cabernet Sauvignon, matematičko modeliranje, računalna analiza slike

**Rad sadrži:**  
60 stranica  
38 slika  
9 tablica  
37 literaturnih referenci

**Jezik izvornika:** Hrvatski

#### Sastav Povjerenstva za ocjenu i obranu diplomskog rada i diplomskog ispita:

- |    |                                                 |               |
|----|-------------------------------------------------|---------------|
| 1. | izv. prof. dr. sc. <i>Marko Jukić</i>           | predsjednik   |
| 2. | prof. dr. sc. <i>Daliborka Koceva Komlenić</i>  | član-mentor   |
| 3. | izv. prof. dr. sc. <i>Jasmina Lukinac Čačić</i> | član-komentor |
| 4. | izv. prof. dr. sc. <i>Mirela Planinić</i>       | zamjena člana |

**Datum obrane:** 4. travnja 2019.

Rad je u tiskanom i elektroničkom (pdf format) obliku pohranjen u Knjižnici Prehrambeno-tehnološkog fakulteta Osijek, Franje Kuhača 20, Osijek.

## BASIC DOCUMENTATION CARD

## GRADUATE THESIS

University Josip Juraj Strossmayer in Osijek Faculty of Food Technology Osijek

Department of Food Technology

Subdepartment of Cereal Technology

Franje Kuhača 20, HR-31000 Osijek, Croatia

**Scientific area:** Biotechnical sciences  
**Scientific field:** Food technology  
**Course title:** Technology of Flour Production and Processing  
**Thesis subject** was approved by the Faculty Council of the Faculty of Food Technology at its session no. X.held on July 4, 2018  
**Supervisor:** *Daliborka Koceva Komlenić*, PhD, professor  
**Co-supervisor:** *Jasmina Lukinac Čačić*, PhD, associate professor  
**Technical assistance:** *Marko Jukić*, PhD, associate professor

### Mathematical Modelling of the Kinetics Related to the Change in Colour of Tea Biscuits with the Addition of the Pomace from the Grape Variety Cabernet Sauvignon

*Tena Balen*, 412-DI

#### Summary:

In this paper, mathematical modelling of the kinetics of the change of the colour of the tea biscuits during the baking process was investigated with the aim of predicting the change of colour and determining the optimal conditions for the production of the tea biscuits. Samples of tea biscuits were produced in laboratory conditions from wheat flour T-550 with addition of pomace from the grape variety Cabernet Sauvignon. Tasting samples of the tea biscuits were carried out with different proportions of pomace from the grape variety Cabernet Sauvignon (10, 20 and 30%). For the purposes of mathematical modelling and determination of kinetic parameters, colour samples was determined by digital image analysis method. Success in approximating experimental data to kinetic models were evaluated using various statistical criteria:  $R^2$  and RMSE.

According to the obtained results of testing several kinetics models, the logistic sinusoidal model proved to be the most suitable for predicting the colour change of all analysed samples of tea biscuits for all tested independent model variables ( $\Delta E$ , BI, 100-L, SI, DI and BCI).

**Keywords:** Tea Biscuit, Cabernet Sauvignon Grape Pomace, Mathematical Modelling, Digital Image Analysis

**Thesis contains:** 60 pages  
38 figures  
9 tables  
37 references

**Original in:** Croatian

#### Defense committee:

- |    |                                                         |               |
|----|---------------------------------------------------------|---------------|
| 1. | <i>Marko Jukić</i> , PhD, associate professor           | chairperson   |
| 2. | <i>Daliborka Koceva Komlenić</i> , PhD, professor       | supervisor    |
| 3. | <i>Jasmina Lukinac Čačić</i> , PhD, associate professor | co-supervisor |
| 4. | <i>Mirela Planinić</i> , PhD, associate professor       | stand-in      |

**Defense date:** April, 4<sup>th</sup> 2019

**Printed and electronic (pdf format) version of thesis is deposited in** Library of the Faculty of Food Technology Osijek, Franje Kuhača 20, Osijek.

## Sadržaj

<b>1.UVOD .....</b>	<b>1</b>
<b>2.TEORIJSKI DIO .....</b>	<b>3</b>
2.1. ČAJNO PECIVO .....	4
2.2. SIROVINE ZA PROIZVODNJU ČAJNOG PECIVA .....	5
2.3. TROP GROŽĐA .....	7
2.3.1. Peteljka.....	8
2.3.2. Kožica .....	8
2.3.3. Sjemenka.....	9
2.4. BOJA.....	9
2.5. PROSTOR BOJA .....	11
2.5.1. RGB prostor boja.....	11
2.5.2. CIE <i>Lab</i> prostor boja.....	12
2.6. RAZVOJ BOJE NA POVRŠINI ČAJNOG PECIVA .....	12
2.7. UREĐAJI ZA MJERENJE BOJE .....	13
2.7.1. Kolorimetar .....	14
2.7.2. Sustav za računalnu analizu slike .....	14
2.8. MODELIRANJE PROMJENE BOJE.....	17
2.8.1. Kinetika kemijske reakcije.....	17
<b>3. EKSPERIMENTALNI DIO .....</b>	<b>22</b>
3.1. ZADATAK.....	23
3.2. MATERIJAL .....	23
3.3. METODE.....	23
3.3.1. Mjerenje boje čajnog peciva računalnom analizom slike.....	24

3.3.2. Modeliranje kinetike promjene boje čajnog peciva tijekom pečenja .....	28
3.3.3. Statistička obrada rezultata .....	32
<b>4. REZULTATI I RASPRAVA .....</b>	<b>33</b>
4.1. REZULTATI MJERENJA BOJE ČAJNOG PECIVA RAČUNALNOM ANALIZOM SLIKE .....	35
4.2. REZULTATI MATEMATIČKOG MODELIRANJA PROMJENE BOJE ČAJNOG PECIVA S DODATKOM TROPA GROŽĐA .....	40
<b>5. ZAKLJUČCI.....</b>	<b>54</b>
<b>6. LITERATURA.....</b>	<b>57</b>

## Popis oznaka, kratica i simbola

100-L	indeks gubitka svjetline
AA	akrilamid
AACC	American Association of Cereal Chemists
$a^*$	kormatska komponenta CIEL $*a^*b^*$ prostora boja (zeleno-crveno)
$b^*$	kormatska komponenta CIEL $*a^*b^*$ prostora boja (plavo-žuto)
BCI	indeksa boje pečenja
BI	indeks posmeđivanja
DI	indeks tamnjenja
$\Delta E$	ukupna promjena boje
HMF	hidroksimetilfurfural
$k$	konstanta brzine reakcije
$L^*$	parametar CIEL $*a^*b^*$ prostora boja - svjetlina (eng. <i>lightness</i> )
NN	Narodne novine
$R^2$	koeficijent determinacije, statistički parametar
RMSE	srednje kvadratno odstupanje, statistički parametar
SI	indeks saturacije
$t_{1/2}$	vrijeme polureakcije
tgCS10	čajno pecivo s dodatkom 10% tropa grožđa sorte Cabernet Sauvignon
tgCS20	čajno pecivo s dodatkom 20% tropa grožđa sorte Cabernet Sauvignon
tgCS30	čajno pecivo s dodatkom 30% tropa grožđa sorte Cabernet Sauvignon

## **1.UVOD**

Nastanak boje na površini keksarskih proizvoda tijekom pečenja smatra se poželjnim svojstvom, a nastaje kao rezultat reakcija neenzimskog posmeđivanja (Hodge, 1953). Kod čajnih peciva, smeđa boje potječe od netopivog smeđeg pigmenta melanoidina i karamela koji su produkti reakcija neenzimskog posmeđivanja (Wahlby i Skjoldebrand, 2002.)

Čajno pecivo je proizvod koji se konzumira u cijelom svijetu. Prema Pravilniku NN 81/16 čajno pecivo je proizvod koji se dobije pečenjem oblikovanog tijesta. Razlozi popularnosti proizvoda poput čajnog peciva popularni jesu: odmah su spremni za konzumaciju, dobre su nutritivne vrijednosti, mogu se dugo skladištiti te zaslađivati i aromatizirati dodavanjem različitih okusa (Acun i Gül, 2013).

Trop grožđa nastaje tijekom proizvodnje vina. To je kruti otpad koji se sastoji od kože, pulpe i sjemenki, a ponekad i od peteljki grožđa (Bucić-Kojić i sur., 2017). Tijekom vinifikacije nastaju velike količine ovog nusproizvoda koje je teško odlagati i uzrokuju onečišćenje okoliša (Acun i Gül, 2013). Zbog svog kemijskog sastava (prirodni izvor antioksidanasa, bogat vlaknima i fenolnim spojevima) i lake dostupnosti ovaj otpad prehrambene industrije može biti dobar izvor za proizvodnju različitih produkata.

Brzina razvoja boje na površini čajnog peciva ovisi o procesnim uvjetima kao što su temperatura i vrijeme pečenja. Direktne metode određivanja boje usmjerene su na kvantitativno praćenje produkata koji nastaju tijekom pečenja dok indirektne metode mjere količinu reflektirane svjetlosti s površine uzorka.

Cilj diplomskog rada bio je proizvesti čajno pecivo s dodatkom različitih udjela tropa grožđa sorte Cabernet Sauvignon u laboratorijskim uvjetima i pratiti promjenu boje tijekom pečenja. Boja čajnog peciva odredit će se računalnom analizom slike, a izmjerene vrijednosti CIEL\*a\*b\* parametara boje poslužit će za modeliranja kinetike promjene boje tijekom pečenja i određivanje parametara modela s ciljem predviđanja promjene boje čajnog peciva tijekom pečenja. Za potrebe matematičkog modeliranja, mjereni parametri boje CIEL\*a\*b\* sustava boje preračunat će se u različite indekse boje: ukupnu promjene boje ( $\Delta E$ ), indeks posmeđivanja (BI), indeks gubitka svjetline ( $100-L$ ), indeks saturacije (SI), indeks tamnjenja (DI) te indeks boje pečenja (BCI).



## **2.TEORIJSKI DIO**

## 2.1. ČAJNO PECIVO

Čajno pecivo je proizvod dobiven pečenjem oblikovanog tijesta, a sadrži najmanje 10% masti ili ulja i najviše 5% vode, računato na ukupnu masu gotovog proizvoda (Pravilnik o žitaricama i proizvodima od žitarica, NN 81/16).

Razlikujemo čajna peciva prema:

1. udjelu masti koju sadrže:

- desertna čajna peciva s najmanje 20% masnoće,
- čajna peciva prve kvalitete s najmanje 15% masnoće i
- čajna peciva druge kvalitete s najmanje 10% masnoće.

Kod ovih proizvoda udio masnoće se također računa na gotov proizvod s najviše 5% vode.

2. svojstvima sirovina, sastavu tijesta te načinu obrade i rada strojeva za oblikovanje:

- prešano,
- sječeno,
- oblikovano (formirano) i
- istisnuto (dresirano) (Gavrilović, 2011).

3. Prema tvrdoći zamjes može biti:

- tvrdi zamjes tijesta koji ima veći udio vode i relativno malo masnoće i šećera. Tijesto je tvrdo, čvrsto i rastezljivo (može se rastezati, a da ne dođe odmah do pucanja).
- meki zamjes tijesta sadrži relativno visoke udjele masnoće i šećera, a manji udio vode.

Takvo tijesto lako puca što znači da mu je rastezljivost mala. (Manley, 2000.).



Slika 1. Čajno pecivo (Web 1)

## 2.2. SIROVINE ZA PROIZVODNJU ČAJNOG PECIVA

Osnovne sirovine u proizvodnji finih pekarskih i srodnih proizvoda su:

- mlinski proizvodi,
- voda,
- masnoće,
- šećer i
- sredstva za narastanje (Koceva Komlenić i Jukić, 2018., Gavrilović, 2011).

U dodatne sirovine spadaju sredstva za narastanje koja su iznimno važna zbog formiranja strukture tijekom pečenja, uz sredstva za narastanje tu su još i aditivi, jaja, i med koji mogu utjecati na reološka svojstva tijesta.

**Pšenično brašno** - u proizvodnji čajnog peciva najčešće korišteni tipovi pšeničnog brašna su T-400 i T-550. Granulacija brašna je od velike važnosti, a izbor brašna ovisi o sirovinskom sastavu tijesta i načinu mehaničke obrade (Gavrilović, 2011). U proizvodnji se koriste brašna s niskim udjelom proteina jer preveliki razvoj glutena nije poželjan (Gavrilović, 2011).

**Masnoće** - u proizvodnji čajnih peciva koriste se različite masnoće, bilo da su prirodne, hidrogenizirane, ili emulgirane. U tijestu za čajno pecivo mast je raspodijeljena u tankim

slojevima i povezana preko svojih hidrofobnih veza s hidrofobnim vezama proteina brašna (Gavrilović, 2011). Mast se raspoređuje po česticama brašna i pri tome omogućuje pristup vodi i hidratizaciju proteina i škroba. Porastom temperature tijekom zamjesa, dio masti s obzirom na svoja plastična svojstva (posebno *shortening*) sporo prelazi u tekuću fazu što povoljno utječe na proces hidratacije. Najpoželjnija masnoća za upotrebu u keksarstvu je maslac, dok se biljna mast najviše upotrebljava (Gavrilović, 2003).

**Šećer** - saharoza se najviše koristi u proizvodnji keksarskih proizvoda. Osim što je daje okus slatkoće, utječe i na teksturu i strukturu keksa te na viskoznost tijesta. O količini dodanog šećera u zamjesu također ovise i tvrdoća, svježina (hrskavost), boja i volumen čajnog peciva (Hoseney, 1994). Kristal šećer ima manju prednost uporabe u odnosu na šećer u prahu. Kod izrade mase za punjenje koristi se fino mljeveni šećer u prahu.

Osim zaslađivanja saharoza ima neke dodatne pozitivne učinke u proizvodnji:

- usporava bubrenje škroba,
- smanjuje osmotski tlak vode,
- omekšava gluten i omogućuje čvrstoću keksu i
- smanjuje viskoznost tijestu (Koцева Komlenić i Jukić, 2018).

**Voda** - u tijestu se nalazi u slobodnom ili vezanom obliku. Vezana voda se nalazi u sastavu glutena dok kapilarnu vodu prima škrob. Upravo visoko-elastična svojstva tijesta ovise o udjelu slobodne vode (Gavrilović, 2011).

**Sredstva za narastanje** - u proizvodnji keksa i srodnih proizvoda, kao aditivi upotrebljavaju se kemijska i biokemijska sredstva za narastanje tijesta. Biokemijsko sredstvo za narastanje tijesta je pekarski kvasac (*Saccharomyces cerevisiae*), dok najčešće upotrebljavana kemijska sredstva su amonijev hidrogenkarbonat i natrijev hidrogenkarbonat. Kemijska sredstva utječu na promjenu pH sredine tijesta, sprječavaju ljepljivost tijesta i zbog toga je moguće stanjivanje tijesta tijekom mehaničke obrade (Gavrilović, 2003).

**Sol** - kuhinjska sol je bezbojni kristal. Mijenja fizikalna svojstva tijesta tako što pridonosi učvršćivanju glutena (Koцева Komlenić i Jukić, 2018). Dodaje se 1,8 - 2,1% soli na suhu tvar

brašna, što iznosi 1,1 - 1,4% soli u kruhu. Sol se može dodavati na dva načina: u suhom obliku ili kao vodena otopina (sol otopljena u vodi potrebnoj za zamjes) (Kent i Evers, 1994).

**Pekarski kvasac** - može se koristiti u svježem stanju (oko 70% vode) ili u suhom aktivnom obliku (Kent i Evers, 1994). Tijekom fermentacije, djelovanjem enzima kvasca dolazi do razgradnje šećera do vode i CO<sub>2</sub> koji u tijestu stvara pore.

### 2.3. TROP GROŽĐA

Trop (drop, komina, kom) je čvrsti ostatak koji zaostaje nakon procesa tiještenja (prešanja) izmuljenog ili usitnjenog voća, ponajprije grožđa. Trop se sastoji od peteljki, kože, sjemenki i manjeg udjela pulpe. Mogućnosti upotrebe tropa grožđa:

- stočna hrana,
- biognojivo,
- ulje sjemenki grožđa,
- izvor bioaktivnih polifenolnih spojeva,
- proizvodnja enzima,
- proizvodnja biogoriva (bioetanola, bioplina, biodizela) (Bucić-Kojić i sur., 2017.).

Kemijski sastav i zastupljenost pojedinih dijelova grožđa u tropu grožđa ovisi o sorti grožđa, procesu vinifikacije i jačini prešanja.

**Tablica 1.** Raspodjela najzastupljenijih fenolnih spojeva po komponentama tropa grožđa (Fuleki i da Silva, 1997; Shi i sur., 2003; Yilmaz i Toledo, 2006; Xia i sur., 2010)

Dio tropa grožđa	Fenolni spoj
Sjemenka	galna kiselina, (+)-katehin, (-)-epikatehin, epikatehin-3-O-galat, (-)-galokatehin, (-)-epigalokatehin, dimeri, trimeri, tetrameri (procijanidini), proantocijanidini
Kožica	miricetin, kvercetin, kempferol, trans-reveratrol, elaginska kiselina proantocijanidini, antocijanini
Peteljka	rutin, kvercetin-3-glukuronid, astilbin, trans-resveratrol

**Tablica 2.** Kemijski sastav tropa grožđa (Llobera i Cañellas, 2007; Manara i sur., 2014; Sousa i sur., 2014; Tseng i Zhao, 2013; Zheng i sur., 2012)

Otpad vinarija	Sastojak	Udio (% s.tv.)
Trop grožđa	Ukupna vlakna	46,2 - 74,5
	Pektin	3,7 - 6,2
	Lignin	28,7 - 42,2
	Celuloza	9,2 - 14,5
	Hemiceluloza	4 - 10,3
	Proteini	7,0 - 23,5
	Lipidi	8,2 - 13,5
	Šećeri	2,7 - 49,1
	Pepeo	4,7 - 9,5
	Tanini	12,1 - 22,3
	Ukupni polifenoli	4,8 - 6,7
	Ukupni ugljik	44,3 - 52,9
	Ukupni dušik	1,2 - 4,5

### 2.3.1. Peteljka

Peteljka predstavlja kostur grozda. Sastoji se od osnovnog dijela koji se grana, završava sa peteljčicama koje nose cvijet i nakon oplodnje bobicu. Upotrebljava se kao stočna hrana, dodatak u prehrani tla, a ima i potencijal biokonverzije u visokovrijedne proizvode (aktivni ugljen, polifenoli i dijetalna vlakna) (Bucić-Kojić i sur., 2017).

### 2.3.2. Kožica

Kožica grožđa ima najveći udio u tropu grožđa. Uglavnom se koristi kao stočna hrana, a ekstrakt kože se koristi kao pojačivač boje (Bucić-Kojić i sur., 2017). Po kemijskom sastavu kožica je siromašna šećerima, a bogata je celulozom i netopljivim pektinima i proteinima.

### 2.3.3. Sjemenka

Sjemenka se sastoji od masne jezgre koju okružuje drvena ljuska prekrivena taninskom kutikulom. Prešani trop grožđa sadrži 20 do 30% sjemenki. Sjemenke grožđa sadrže oko 40% vlakana, 16% ulja, 11% proteina i 7% polifenolnih spojeva, nešto šećera i mineralnih tvari. Ekstrakt sjemenki grožđa se koristi kao suplement prehrani, a ima i antibakterijski učinak zbog čega se može koristiti kao aditiv u prehrambenoj industriji i u proizvodnji preparata koji sprečavaju nastanak karijesa.

### 2.4. BOJA

Osjet boje predstavlja psihofizički doživljaj koji ovisi o izvoru svjetla, psihološkim i fiziološkim uvjetima promatrača i karakteristikama objekta koji se promatra. Često je boja svojstvo prehrambenih proizvoda koje se prvo uočava i direktno pretvara u pozitivan ili negativan predznak ukupne kvalitete proizvoda.

Doživljaj boje ovisan je o tri faktora:

- spektralnom sastavu svjetla koje pada na promatrani predmet,
- molekularnoj strukturi materijala s kojeg se svjetlo reflektira ili koje ga propušta i
- čovjekovim osjetom boje, kroz oči i mozak (Lukinac Čačić, 2012).


Ono što ljudi i neke životinje percipiraju kao boju je u biti reflektirana svjetlost s površine nekog objekta, zbog čega je karakteriziranje svjetlosti izuzetno bitno za znanost o bojama i korištenje boje u računalnom vidu (Filko, 2013).

Kada opisujemo boju koristimo njena svojstva kao što su:

- $h^\circ$  – ton boje ili tonalnost boje (engl. *hue*)
- $S$  – zasićenost ili saturacija (engl. *saturation*)
- $L$  – svjetlina ili luminancija (engl. *lightness*).

**Ton boje** označava vrstu boje te se definira kao kromatska kvaliteta boje, odnosno kvaliteta kojom se jedna boja razlikuje od druge. Ton može poprimiti vrijednosti  $0^\circ$  -  $360^\circ$  koji određuju

položaj boje na kružnoj paleti boja. Crvena boja se nalazi na  $0^\circ$  (ili  $360^\circ$ ), zelena na  $120^\circ$ , a plava na  $240^\circ$ . Da bi se objasnili pojmovi zasićenost i svjetlina, najprije je potrebno boje podijeliti u dvije osnovne skupine. U prvoj skupini nalaze se prave boje, kao što su crvena, narančasta, žuta, zelena, plava itd., koje se nazivaju kromatskim bojama, a prikazane su na **Slici 2**.




Slika 2. Kromatske boje (Web 2)

U drugoj skupini boja nalaze se crna, siva i bijela, koje se nazivaju akromatskim bojama ili nebojama i čine skalu koja seže od crne, preko sive, do bijele. Na **Slici 3** prikazane su akromatske boje.



Slika 3. Akromatske boje (Web 3)

**Svjetlina  $L^*$**  (engl. *lightness*) je osobina kromatske boje koja je usporediva sa svjetlinom sive akromatske boje. Svjetlina se također izražava u postocima 0% - 100%. Vrijednost 0% će dati crnu, a 100% bijelu boju. **Slika 4** prikazuje svjetlinu boje.



Slika 4. Svjetlina boje (Web 4)



**Zasićenost boje  $S$**  (engl. *saturation*) je stupanj čistoće boje, određen udjelom akromatskih boja (crna, siva, bijela) u kromatskim bojama (crvena, narančasta, žuta, zelena, itd.). Zasićenost se izražava u postocima. Na **slici 5** može se vidjeti da vrijednost 0% daje sivu boju, a 100% čistu boju (Lukinac Čačić, 2012.).



Slika 5. Zasićenost boje (Web 5)

## 2.5. PROSTOR BOJA


Prostor boja ili model boja je način pomoću kojeg se definiraju, stvaraju i vizualiziraju boje.

Osnovna podjela prostora boja je na:

- aditivni prostor boja, ovisan o uređaju, kod kojeg se boja dobiva zbrajanjem pojedinih komponenti (npr. RGB)
- subtraktivni prostor boja, neovisan o uređaju, kod kojeg se boja dobiva oduzimanjem pojedinih komponenti (npr. CIE  $L^*a^*b^*$ ).

### 2.5.1. RGB prostor boja


RGB prostor boja definiran je pomoću tri aditivna primara: crvene, zelene i plave boje. Svaka boja u tom prostoru boja nastaje zbrajanjem pojedinih komponenata te tri boje. RGB model predstavljen je pomoću kocke, gdje crvena boja predstavlja x-os, zelena boja y-os, a plava boja z-os (Puglia, 2000). **Slika 6** prikazuje model RGB prostora boja.



Slika 6. RGB prostor boja (Web 6)

### 2.5.2. CIE*Lab* prostor boja

CIE*Lab* prostor boja je trodimenzionalni prostor boja baziran na percepciji boje standardnog promatrača. Kratica *Lab*, označava tri komponente ovog modela koje prikazuje **Slika 7.** Prednost ovog sustava je i uvođenje svjetline kao treće dimenzije. Numeričke vrijednosti u CIE *L\*a\*b\** sustavu opisuju sve boje koje može razlikovati ljudsko oko. CIE *L\*a\*b\** sustavu boje su opisane pomoću tri osi: dvije kromatske, *a\** komponenta odnos između crvene i zelene boje (negativne vrijednosti označavaju zelenu, a pozitivne crvenu), a *b\** komponenta odnos između žute i plave boje (negativne vrijednosti za plavu, a pozitivne za žutu). *L\** komponenta određuje svjetlinu, akromatska os mjeri se od 0 do 100 po vertikalnoj osi, gdje je 0 vrijednost za crnu, a 100 za bijelu **Slika 7.** (Yam i Papadakis, 2004.; Hsien-Che, 2005.)



**Slika 7.** Prikaz CIE*Lab* prostora boja (Web 7)

### 2.6. RAZVOJ BOJE NA POVRŠINI ČAJNOG PECIVA

Proces pečenja je jedna od najvažnijih faza u proizvodnji finih pekarskih i srodnih proizvoda. Temperatura raste, a dolazi i do fizikalno-kemijskih promjena. Dehidracija, koagulacija bjelančevina, karamelizacija šećera, bubrenje i želatinizacija su najvažnije promjene koje se događaju pri određenim temperaturama:

- 50 - 60 °C - koagulacija bjelančevina, a gluten omekšava i otpušta dio vode,
- 60 - 90 °C - razgradnja kemijskih sredstava za narastanje pri čemu nastaju plinovi i voda koja prelazi u vodenu paru te time povećava volumen i poroznost proizvoda,
- 80 °C - škrob maksimalno bubri i
- 160 °C - karamelizacija šećera (Gavrilović, 2011).

Smeđa boja keksa potječe od melanoidina (netopivog smeđeg pigmenta) i karamela koji se razvijaju u proizvodu tijekom Maillardovih reakcija te karamelizacije. Na stvaranje žuto-smeđe boje kore čajnih peciva utječe nizak udjel vode i povišena temperatura (Broyart i sur. 1997.; Purlis i Salvadori, 2007). Obojenje proizvoda započinje pojavom svijetlih, žutih dekstrina pri temperaturama 110 - 120 °C (Wahlby i Skjoldebrand, 2002.), daljnjim povišenjem temperature najprije nastaju produkti Maillardovih reakcije i karamelizacije (melanoidini i karamel), a nakon toga dolazi do izgaranja proizvoda i nastanka crne porozne mase. Melanoidini nastaju tek kada je temperatura na površini proizvoda viša od 120 °C (Broyart i sur. 1997.; Purlis i Salvadori, 2007). Razvoj produkata karamelizacije (karamela) nastaje kada je temperatura na površini proizvoda viša od 200 °C i pri niskom udjelu vode (Yildiz, 2009.; Quintas i sur., 2002.). Maillardove reakcije su reakcije koje nastaju između proteina i reducirajućih šećera. Osim razvoja poželjnih svojstva kao što su aroma i boja, mogu nastati i nepoželjni produkti poput hidroksimetilfurfurala (HMF) i akrilamida (AA). Na prirodu Maillard-ovih reakcija i prirodu produkata koji nastaju utječu svojstva okoline tj. svojstva samog medija odnosno namirnice kao što su aktivitet vode, pH, kemijski sastav i temperatura (Martins i sur., 2001.). Navedenim reakcijama osim boje razvijaju se i tvari arome te nepoželjni produkti s potencijalnim mutagenim djelovanjem poput hidroksimetilfurfurala i akrilamida.

## 2.7. UREĐAJI ZA MJERENJE BOJE

Boja namirnice prvi je doživljaj kod potrošača prilikom odabira. U tehnološkom smislu boja je svojevrsni indikator kvalitete te mogućih anomalija ili oštećenja proizvoda koja nastaju tijekom prerade, proizvodnje i skladištenja (Pedreschi i sur., 2007.a, 2007.b). Direktne metode mjerenja boje usmjerene su na kvantitativno praćenje produkata Maillardovih reakcija i karamelizacije (AA, HMF i furfurala) (Ramirez - Jimenez, 2000.), dok se indirektne metode zasnivaju na principu mjerenja reflektirane količine svjetlosti s površine analiziranog uzorka različitim mjernim uređajima. Uređaji za indirektno određivanje boje koji se često primjenjuju u praksi su: kolorimetar, kromametar, spektrofotometar, denziometar (Gokmen i sur., 2008.a; Purlis i Salvadori, 2007.), a u novije vrijeme sustav za računalnu analizu slike (Brosnan i Sun, 2002., 2004.; Zeng i sur., 2007.; Magdić i sur., 2006.).

### 2.7.1. Kolorimetar

Uređaj se sastoji od mjerne glave s otvorom promjera 8 mm, a rad mu se temelji na mjerenju reflektirane svjetlosti s površine osvijetljenog uzorka. Prije svakog mjerenja mora se kalibrirati pomoću standardne bijele keramičke pločice (CR-A43). Vrijeme mjerenja je 1 s sa minimalnim intervalom između mjerenja 3 s. Jedna od najvažnijih prednosti kolorimetra je da omogućava izračunavanje  $\Delta E$  razlike boja, na temelju razlika u svjetlini, tonu i kromatičnosti. Glavni nedostatak kolorimetra je nemogućnost registriranja metamernih boja. U ovom radu korišten je kolorimetar Konica Minolta CR-400 prikazan na **Slika 8**.




**Slika 8.** Kolorimetar Konica Minolta CR-400 (Web 8)

### 2.7.2. Sustav za računalnu analizu slike

Boja površine uzorka primjenom računalne analize slike (engl. *Digital image analysis*, DIA) određuje se beskontaktno. Primjenom odgovarajućih računalnih algoritama moguće je dobiti vrlo točne i pouzdane informacije o promjeni boje proizvoda koje nastaju tijekom proizvodnje. Ova metoda za praćenje boje može se koristiti kao alat za automatsko vođenje procesa u industriji (za vizualni pregled procesa proizvodnje) te time poboljšati ukupnu kvalitetu proizvoda. Prednost sustava za analizu slike, nad praćenjem boje ljudskim okom je objektivnost i kontinuiranost u procjeni boje. Sustav za analizu slike boju uzorka registrira s tri

senzora boje, a sastoji se od tri najvažnija elementa: rasvjete, fotoaparata i računala (Lukinac Čačić, 2012.) što je prikazano na Slici 9.



**Slika 9.** Elementi sustava za računalnu analizu slike

### 2.7.2.1. Rasvjeta

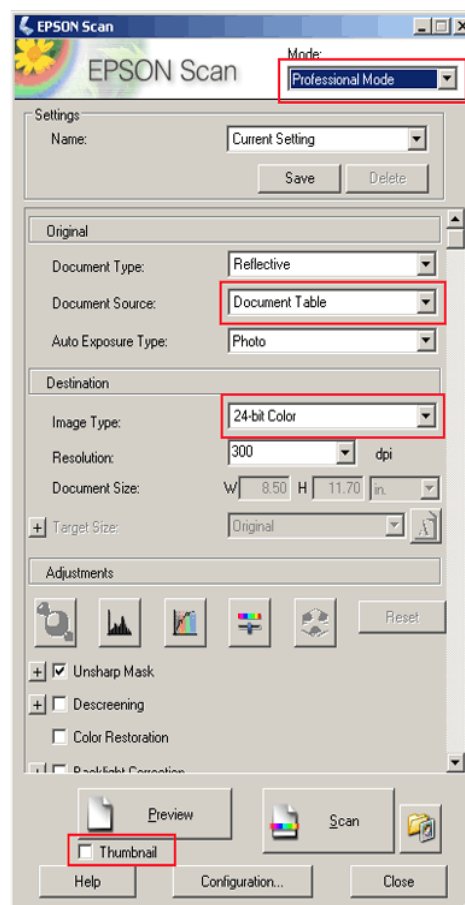
Izvor svjetlosti je fizički realizirano zračenje (svijeća, lampa, sunce). Izvor svjetlosti karakteriziraju svojstva poput raspodjela spektralnog zračenja i temperature boje svjetlosti. Kut između osi objektiva fotoaparata te izvora svjetlosti koja osvjetljava uzorak trebao bi biti oko  $45^\circ$  (Yam i sur., 2004.). Pri toj vrijednosti kuta između kamere i izvora svjetlosti, većina objekata difuzno reflektira svjetlost (najbolja refleksija svjetlosti s uzorka na senzor slike).

### 2.7.2.2. Skener

Skener (engl. scanner) je uređaj koji služi za digitalizaciju fotografija, crteža i transparentnih medija (npr. negativ filma, dijapozitiv, prozirnica itd.). Princip rada skenera zasniva se na pretvorbi svjetlosti. Kada svjetlost padne na objekt ona se reflektira i putem optičkog sustava, zrcala i leća, dolazi do fotosenzora koji stvaraju električni signal. Taj električni signal se tada posebnim sustavom pretvara u digitalnu informaciju i šalje u računalo. Slika se pri tom postupku dijeli u točke i što je više tih točaka, to će slika biti veće kvalitete. Broj očitanih točaka naziva se razlučivost ili rezolucija. U ovom diplomskom radu je korišten Epson Perfection V500 Photo (Slika 10).



a

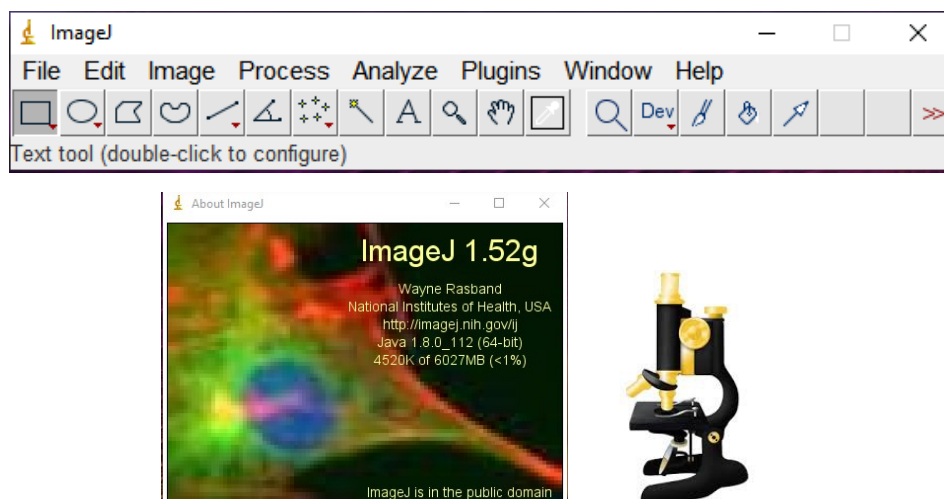


b

**Slika 10.** Skener EPSON Perfection V500 Photo (a), sučelje programa Epson Scan (b) (Web 9)

### 2.7.2.3. Image J

*ImageJ* (ver. 1.52g; National Institute of Mental Health, Bethesda, Maryland, USA) je program otvorenog koda za analizu slike napisan u programskom jeziku Java. Autor programa je Wayne Rasband. Program radi kao online/download aplikacija koja radi na različitim platformama (Windows, MacOS, MacOs x, Linux). Program ima korisničko sučelje (Slika 11) s funkcijama za učitavanje, prikazivanje, analiziranje, spremanje i ispis 8, 16 i 32 bitne slike raznih formata: TIFF, GIF, JPEG, BMP i DICOM. Osim standardnih funkcija obrade slike, program omogućuje određivanje brojnih motometrijskih pokazatelja objekata (površina, oplošje, faktor oblika i slično), nudi mogućnosti geometrijske transformacije (rotacija i skaliranje). U programu je moguće izračunati područje i vrijednost piksela, izmjeriti udaljenosti i kutove, a sadrži i opcije za podešavanje kontrasta, izoštravanje, poravnavanje i dr. Program nudi automatizirane, reproducibilne tijekove rada preko skripti i makronaredbi.



**Slika 11.** Izgled glavnog menija ImageJ programa

## 2.8. MODELIRANJE PROMJENE BOJE

U postupku proizvodnje čajnog peciva, proces pečenja bitan je čimbenik za razvoj kvalitativnih svojstava (boja, aroma, tekstura), koja nastaju kao rezultat toplinskih procesa u tijestu poput neenzimskog posmeđivanja, želatinizacije škroba, denaturacije proteina. Boja keksa rezultat je reakcija neenzimskog posmeđivanja, njihovim praćenjem tijekom procesa pečenja moguće je utjecati na konačnu boju proizvoda. Brzina razvoja boje na površini proizvoda ovisi o procesnim parametrima poput temperature i vremena pečenja, zatim udjelu vode u proizvodu, aktivitetu vode proizvoda, pH vrijednosti, udjelu reducirajućih šećera i dr.

### 2.8.1. Kinetika kemijske reakcije

Kemijska kinetika je područje fizikalne kemije koja se bavi proučavanjem brzine i mehanizama kemijskih reakcija. Osnovni pojmovi bitni u području kemijske kinetike su mehanizam kemijske reakcije, brzina kemijske reakcije, konstanta brzine kemijske reakcije, molekularnost i red reakcije. Obzirom na složenost razlikujemo osnovne kemijske reakcije (u kojima se u jednom stupnju od reaktanata dolazi do produkata) te složene kemijske reakcije (u kojima se reakcija odvija preko niza među stupnjeva u kojima se javljaju neposredne međureakcije).

Bilo koju kemijsku reakciju možemo opisati kao vremenski proces pri kojemu dolazi do promjene reaktanata u produkte. Kako bi matematički interpretirali ovaj proces pomoću dinamičkih sustava potrebno je pojednostaviti situaciju te napraviti slijedeće pretpostavke:

- Proces se odvija u zatvorenom sustavu konstantnog volumena ( $V = \text{konst.}$ )
- Temperatura procesa je konstantna ( $T = \text{konst.}$ )

**Brzina kemijske reakcije** ( $v$ ) – opisuje napredovanje kemijske reakcije u vremenu. Brzina kemijske reakcije iskazuje se kao omjer prirasta množinske koncentracije nekog reaktanta ili produkta,  $\Delta c(X)$ , i vremenskog intervala u kojemu se kemijsku reakciju promatra.

Brzina raspadanja reaktanta dana je jednadžbom:

$$v = - \frac{1}{\nu_i} \cdot \frac{dc_i}{dt} \quad (1)$$

Brzina nastajanja produkata dana je jednadžbom:

$$v = \frac{1}{\nu_i} \cdot \frac{dc_i}{dt} \quad (2)$$

Gdje su:

$v$  – brzina kemijske reakcije,  $\nu_i$  – stehiometrijski koeficijent,  $\frac{dc_i}{dt}$  – promjena koncentracije tvari  $i$  tijekom vremena.

Mjerenje brzine kemijske ne predstavlja ništa drugo nego određivanje promjene koncentracije tijekom vremena. Brzinu kemijske reakcije možemo odrediti direktno (gravimetrijski, volumetrijski) ili indirektno mjerenjem fizikalnih veličina koje su direktno proporcionalne koncentraciji (spektrofotometrijski, konduktometrijski, mjerenjem tlaka, polarimetrijski i sl.).

**Konstanta brzine kemijske reakcije** ( $k$ ) – jednaka je brzini dane kemijske reakcije pri jediničnim koncentracijama tvari u reakciji.

$$v = \pm \frac{1}{\nu_i} \cdot \frac{dc_i}{dt} = k \cdot c_i^n \quad (3)$$

Gdje je  $v$  – brzina kemijske reakcije,  $k$  – konstanta brzine kemijske reakcije,  $c_i$  – koncentracija tvari  $i$  tijekom vremena,  $n$  – red kemijske reakcije. U slučaju kada je  $c_i = 1$ , vrijedi  $v = k$ .



**Molekularnost kemijske reakcije** – predstavlja broj molekula koji sudjeluje u jednoj kemijskoj reakciji. Obzirom na molekularnost, postoje monomolekularne, bimolekularne, te trimolekularne kemijske reakcije.

**Red kemijske reakcije** – jednak je zbroju eksponenata iznad koncentracija tvari u jednadžbi za kemijsku reakciju. Primjerice ako je kemijska reakcija dana izrazom:



Brzina kemijske reakcije jednaka je:

$$-\frac{d[A]}{dt} = k \cdot [A]^a \cdot [B]^b \cdot [C]^c, \text{ a red reakcije } n = a + b + c$$

Važno je istaknuti osnovnu razliku između reda kemijske reakcije i molekularnost. Molekularnost kemijske reakcije određuje se teorijski, dok se red kemijske reakcije određuje eksperimentalno. Red reakcije ne ovisi o stehiometriji kemijske reakcije, nego o broju i koncentraciji reaktanata u reakciji.

Obzirom na **red reakcije** ( $n$ ), razlikujemo kemijske reakcije različitog reda. Opći izraz za red reakcije je:

$$v = k \cdot [A]^n \quad (5)$$

Za reakcije prvog reda vrijedi da je  $n = 1$ , kemijske reakcije drugog reda  $n = 2$ , te kemijske reakcije nultog reda kod kojih vrijedi da je  $n = 0$ :

- diferencijalna jednadžba **nultog** reda  $\frac{d[A]}{dt} = -k$ , čijim integriranjem dobivamo slijedeći izraz:  $[A] = [A_0] - k \cdot t$
- diferencijalna jednadžba reakcije **prvog** reda  $\frac{d[A]}{dt} = -k \cdot [A]$ , čijim integriranjem dobivamo slijedeći izraz:  $[A] = [A_0] \cdot e^{-kt}$
- diferencijalna jednadžba reakcije **drugog** reda  $\frac{d[A]}{dt} = -k \cdot [A]^2$ , čijim integriranjem dobivamo slijedeći izraz:  $\frac{1}{[A]} = \frac{1}{[A_0]} + k \cdot t$

Kod određivanja reda kemijske reakcije postoji više različitih metoda:

- **diferencijalne metode** – temelji se na praćenju promjena jednog reaktanta. Na taj način odredi se diferencijalni red reakcije za dati reaktant. Ova metoda polazi od činjenice da je brzina reakcije  $n$ -tog reda proporcionalna  $n$ -tom stupnju koncentracije
- **metoda integriranja** – metoda se temelji na način da se odredi količina tvar koja je izreagirala u različitim vremenskim intervalima te da se podaci unose u izraze za konstantu brzine reakcije prvog, drugog, trećeg ili nekog složenijeg reda. Uspoređivanjem dobijemo vrijednosti  $k$  za pojedine redove reakcija
- **metoda poluvremena reakcije**
- **grafička metoda** – metoda u kojoj se iscrtava krivulja ovisnosti promjene koncentracije reaktanta tijekom vremena

**Tablica 3.** Prikaz matematičkih modela

Reakcije nultog reda $n = 0$	$A \rightarrow \text{produkti}$		
Diferencijalna jednadžba	$-\frac{d[A]}{dt} = k$	Integrirana jednadžba	$[A] = [A_0] - k \cdot t$
Brzina reakcije (brzina ne ovisi o koncentraciji tvari A)	$v = -\frac{d[A]}{dt} = k$	Vrijeme poluraspada	$\tau_{1/2} = \frac{[A_0]}{2k}$
Reakcije prvog reda $n = 1$	$A \rightarrow \text{produkti}$		
Diferencijalna jednadžba	$-\frac{d[A]}{dt} = k \cdot [A]$	Integrirana jednadžba	$[A] = [A_0] \cdot e^{-kt}$
Brzina reakcije (brzina ovisi o koncentraciji tvari A)	$v = -\frac{d[A]}{dt} = k \cdot [A]$	Vrijeme poluraspada	$\tau_{1/2} = \frac{0,693}{k}$
Reakcije drugog reda $n = 2$	$A + A \rightarrow \text{produkti}$		
Diferencijalna jednadžba	$-\frac{d[A]}{dt} = k \cdot [A]^2$	Integrirana jednadžba	$\frac{1}{[A]} = \frac{1}{[A_0]} + k \cdot t$
Brzina reakcije (brzina ovisi o koncentraciji tvari A)	$v = -\frac{d[A]}{dt} = k \cdot [A]^2$	Vrijeme poluraspada	$\tau_{1/2} = \frac{1}{k \cdot [A_0]}$

Kinetički modeli koji se koriste za predviđanje boje proizvoda na bazi brašna mogu se podijeliti u dvije skupine:

- prvu skupinu čine kinetički modeli kod kojih je nezavisna varijabla vrijeme (Tablica 3-4)
- drugu skupinu čine kinetički modeli promjene boje kod kojih je nezavisna varijabla gubitak mase.

**Tablica 4.** Pregled matematičkih modela za predviđanje boje čajnog peciva mjerenjem svjetline uzorka  $L$

Model	Jednadžba modela	Parametri modela
Nulti red – nelinearni oblik $n = 0$	$[L] = [L_0] - k \cdot t$	$k$
Prvi red – nelinearni oblik $n = 1$	$[L] = [L_0] \cdot e^{-kt}$	$k$
Prvi red – linearni oblik $n = 1$	$\ln[L] = \ln[L_0] - k \cdot t$	$k$
Drugi red- nelinearni oblik $n = 2$	$[L] = \frac{[L_0]}{1 + ([L_0] \cdot k \cdot t)}$	$k$
Drugi red – linearni oblik $n = 2$	$\frac{1}{[L]} = \frac{1}{[L_0]} + k \cdot t$	$k$

### **3. EKSPERIMENTALNI DIO**

### 3.1. ZADATAK

Zadatak rada bio je mjerenje promjene boje čajnog peciva od pšeničnog brašna s dodatkom tropa grožđa sorte Cabernet Sauvignon (u udjelima 10, 20 i 30%) u laboratorijskim uvjetima tijekom 10 minuta pečenja. Boja čajnog peciva određena je računalnom analizom slike, a izmjerene vrijednosti prikazane su u CIEL  $a^*b^*$  sustavu boja i korištene su za modeliranje kinetike promjene boje tijekom pečenja. Za potrebe matematičkog modeliranja, parametri boje CIEL  $a^*b^*$  sustava boje preračunati su u različite indekse boje: ukupnu promjene boje ( $\Delta E$ ), indeks posmeđivanja (BI), indeks gubitka svjetline ( $100-L$ ), indeks saturacije (SI), indeks tamnjenja (DI) te indeks boje pečenja (BCI).

### 3.2. MATERIJAL

Sirovine korištene u proizvodnji čajnog peciva su:

- 64 g shortening-a (margarin),
- 130 g šećera (kristal),
- 2,1 g NaCl,
- 2,5 g NaHCO<sub>3</sub>,
- 33 g otopine glukoze (8,9 g glukoze otopljeno u 150 ml destilirane vode),
- 16 g destilirane vode,
- 225 g brašna (oštro pšenično brašno T-550, 14% vlage) i
- trop grožđa (zamjena za pšenično brašno u udjelu 10, 20 i 30%)

### 3.3. METODE

Izrada čajnog peciva provedena je prema standardnoj AACC 10-50.05 metodi (American Association of Cereal Chemists). Sirovine se važu odvojeno na poluautomatskoj laboratorijskoj vagi. Prvo se odvažu masnoća, šećer, sol i NaHCO<sub>3</sub> prema recepturi, dodaju u mikser i miješaju se brzinom 2 tijekom tri minute, a svake minute treba sastrugati sastojke sa stjenke posude.

Koriste se „žičane” mutilice. Nakon tri minute važe se i dodaje u mikser otopina glukoze i destilirana voda. Miješa se jednu minutu brzinom 2 i jednu minutu brzinom 3. Nakon toga se važe, dodaje ukupna količina brašna ili smjesa brašna i tropa grožđa i miješa dvije minute brzinom 2. Svaki 30 sekundi treba skidati sastojke sa stjenke posude. Dobiveno tijesto sakupi se ručno, okruglo oblikuje, stavi u PVC vrećicu te u hladnjak (do 8 °C) tijekom 30 - 60 minuta. Nakon hlađenja tijesto se razvija valjkom za tijesto na debljinu 7 mm u dva poteza valjka (naprijed-nazad) te se izrežu okrugli oblici promjera 60 mm (~35 g). Oblikovane komade treba izvagati i peći tijekom 2, 4, 6, 8 i 10 minuta pri 205 °C. Nakon pečenja čajno pecivo se hladi 30 minuta, potom važe i analizira.

### 3.3.1. Mjerenje boje čajnog peciva računalnom analizom slike

Boja uzoraka čajnog peciva mjerena je računalnom analizom slike na sirovom uzorku (tijestu), te uzorku čajnog peciva tijekom vremena pečenja od 2, 4, 6, 8 i 10 minuta.

Postupak mjerenja boje uzoraka čajnog peciva računalnom analizom slike proveden je u nekoliko koraka:

- prvi korak je digitalizacija uzoraka (skeniranje)
- spremanje skenirane slike čajnog peciva u TIFF formatu
- obrada i analiza slike računalnim programom *ImageJ*
- pretvorba rezultata mjerenja boje iz RGB u CIEL  $a^*b^*$  model boja

Uzorci su digitalizirani pomoću stolnog skenera u boji EPSON Perfection® V500 Photo. Skener je smješten u tamnu komoru, u kontroliranim uvjetima rasvjete (komora ne dopušta osvjetljavanje uzoraka drugim izvorom svjetlosti). Na staklenu plohu skenera položeni su uzorci čajnog peciva te skenirani prema postavkama skenera prikazanim u **Tablici 5**.

Nakon prihvata i digitalizacije slijedi obrada i analiza digitalne slike programom *ImageJ*. Prvi korak u obradi slike bio je kreiranje izreska dimenzija 1146x1146 pixelsa sa originalne slike (dimenzija 2550x3509 pixelsa). Izresci su spremljeni u novu mapu te je na njima uzorak segmentiran primjenom IsoData metode praga (uzorak čajnog peciva izdvojen je od pozadine) (Ridler, 1978., El-Zaart. 2010). Nakon segmentacije i uklanjanja pozadine slijedi analiza boje

čajnog peciva. Primjenom metode amplitudne segmentacije (*amplitude thresholding*) i histograma prvog reda (*color histogram*), dobiveni su rezultati relativne frekvencije svjetlina točaka u slici (RGB vrijednosti točaka u slici). Konačni rezultati mjerenja boje u eksperimentalnom dijelu ovog rada bazirani su na CIEL\*a\*b\* sustavu boja. RGB signali generirani pri skeniranju uzoraka transponiraju se u CIEL\*a\*b\* sustav boja. Transponiranje vrijednosti boja između RGB i CIEL\*a\*b\* sustava boja napravljeno je u nekoliko koraka. Prvi korak je prevođenje RGB vrijednosti u CIEXYZ, a potom se dobivene vrijednosti CIEXYZ prevode u CIEL\*a\*b\* sustav boja (pretvorba iz jednog u drugi sustav boja dana je formulama **6-12**).

**Tablica 5.** Postavke skenera

Vrsta skenera	Stolni skeneri ( <i>flatbed skener</i> )
Optički senzor	Color Epson MatrixCCD™
Izvor svjetla	Bijela LED lampa s ReadyScan™ LED tehnologijom
Optička rezolucija	300 dpi
Način skeniranja	Puna boja
Dubina boje	24 bit boja
Model boja	sRGB
Brzina skeniranja	16,98 msec/line
Tonska gustoća (dinamički raspon)	3,4 Dmaks.
Raspon skeniranja (maksimum)	216 x 297 mm
Način rada skenera	Reflektivan način skeniranja
Izlazni format slike	TIFF
Priključci	USB 2.0 tipa B
Programska podrška	Epson Scan

**Transformacija (konverzija) boja iz jednog u drugi model boja**

Ova metoda podrazumijeva pretvorbu iz RGB u CIEL<sup>\*</sup>a<sup>\*</sup>b<sup>\*</sup> sustav boja u nekoliko koraka (Leon i sur., 2006; Mendoza, 2006; Larrain i sur., 2008).

Normalizacija sRGB vrijednosti pri čemu vrijedi  $0 \leq R, G, B \leq 1$

$$R = \frac{sR}{255}, \quad G = \frac{sG}{255}, \quad B = \frac{sB}{255} \quad (6)$$

$$R' = \left[ \frac{R + 0,055}{1,055} \right]^{2/4} \begin{cases} \text{ako je } R > 0,04045 \\ \text{u protivnom } R' = \frac{R}{12,92} \end{cases}$$

$$G' = \left[ \frac{G + 0,055}{1,055} \right]^{2/4} \begin{cases} \text{ako je } G > 0,04045 \\ \text{u protivnom } G' = \frac{G}{12,92} \end{cases} \quad (7)$$

$$B' = \left[ \frac{B + 0,055}{1,055} \right]^{2/4} \begin{cases} \text{ako je } B > 0,04045 \\ \text{u protivnom } B' = \frac{B}{12,92} \end{cases}$$

$$R_s = R' \cdot 100, \quad G_s = G' \cdot 100, \quad B_s = B' \cdot 100 \quad (8)$$

Pri standardnim vrijednostima D65 i 10° vrijedi:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,4124 & 0,3576 & 0,1805 \\ 0,2126 & 0,7152 & 0,0722 \\ 0,0193 & 0,1192 & 0,9505 \end{bmatrix} \cdot \begin{bmatrix} R_s \\ G_s \\ B_s \end{bmatrix} \quad (9)$$



Prema sljedećim formulama **(10-11)** moguće je izračunati  $L^*$ ,  $a^*$  i  $b^*$  koordinate iz standardnih CIEXYZ vrijednosti:

Tisimulusne vrijednosti bijelog standarda CIE1964., D65, 10°

$$X_{ref} = 95,811, \quad Y_{ref} = 100,00, \quad Z_{ref} = 107,304 \quad (10)$$

$$X' = \frac{X}{X_{ref}}, \quad Y' = \frac{Y}{Y_{ref}}, \quad Z' = \frac{Z}{Z_{ref}}$$

$$X_s = 7,787 \cdot X' + \left(\frac{16}{116}\right) \begin{cases} \text{ako je } X' > 0,008856 \\ \text{u protivnom } X_s = (X')^{1/3} \end{cases}$$

$$Y_s = 7,787 \cdot Y' + \left(\frac{16}{116}\right) \begin{cases} \text{ako je } Y' > 0,008856 \\ \text{u protivnom } Y_s = (Y')^{1/3} \end{cases} \quad (11)$$

$$Z_s = 7,787 \cdot Z' + \left(\frac{16}{116}\right) \begin{cases} \text{ako je } Z' > 0,008856 \\ \text{u protivnom } Z_s = (Z')^{1/3} \end{cases}$$

$$L^* = (116 \cdot Y_s) - 16$$

$$a^* = 500 \cdot \left[\frac{X}{X_s}\right]^{1/3} - \left(\frac{Y}{Y_s}\right)^{1/3} \quad (12)$$

$$b^* = 200 \cdot \left[\frac{Y}{Y_s}\right]^{1/3} - \left(\frac{Z}{Z_s}\right)^{1/3}$$

### 3.3.2. Modeliranje kinetike promjene boje čajnog peciva tijekom pečenja

Kinetički modeli promjene boje pekarskih i keksarskih proizvoda opisani u literaturi mogu se podijeliti u dvije skupine:

- kinetički modeli kod kojih je nezavisna varijabla vrijeme (kinetički modeli reakcija nultog, prvog i drugog reda te eksponencijalni empirijski modeli ili logistički sinusoidalni model)
- kinetički modeli promjene boje kod kojih je nezavisna varijabla gubitak mase proizvoda tijekom pečenja

Pri odabiru kinetičkih modela uzeti su u obzir sljedeći kriteriji:

- da je model jednostavan,
- da sadrži mali broj parametara,
- da zadovoljava kriterij točnosti.

Regresijskom analizom eksperimentalnih rezultata određuju se parametri kinetičkih matematičkih modela, a slaganje eksperimentalnih i (prema modelima) izračunatih vrijednosti određuje se pomoću statističkih parametara ( $R$ ,  $R^2$ , RMSE, EF i sl.).

Modeliranje kinetike promjene boje čajnog peciva s dodatkom tropa grožđa sorte Cabernet Sauvignon tijekom pečenja napravljeno je na eksperimentalnim podacima uzoraka čajnih peciva pečenim na temperaturi 205 °C tijekom 10 minuta. Za potrebe modeliranja promjene boje čajnog peciva tijekom pečenja odabrana su tri kinetička modela kod kojih je nezavisna varijabla vrijeme pečenja: model nultog reda, model prvog reda te logistički sinusoidalni model.

Pregled korištenih matematičkih modela dan je u **Tablici 6**, a za potrebe modeliranja ispitane su različite zavisne varijable ( $\Delta E$ , BI, 100-L, DI, SI i BCI) koje su normalizirane kako bi bile međusobno usporedive.

**Tablica 6.** Pregled matematičkih modela primijenjenih u kinetičkoj analizi s normaliziranim podacima promatranih zavisnih varijabli

Model	Jednadžba modela
Nulti red – normalizirani podaci $n = 0$	$\frac{Y_t - Y_0}{Y_{10} - Y_0} = kt$
Prvi red – normalizirani podaci $n = 1$	$\frac{Y_t - Y_0}{Y_{10} - Y_0} = 1 - e^{-kt}$
Logistički sinusoidalni model (Ureta i sur., 2014)	$\frac{Y_t - Y_0}{Y_{10} - Y_0} = \frac{1}{1 + e^{-k(t-t_{1/2})}}$

gdje su:

- $Y_0$  početna vrijednost promatranog svojstva,
- $Y_t$  vrijednost promatranog svojstva u trenutku  $t$ ,
- $Y_{10}$  vrijednost promatranog svojstva u 10. minuti pečenja
- $k$  konstanta brzine ( $\text{min}^{-1}$ )
- $t$  vrijeme (min)
- $t_{1/2}$  vrijeme polureakcije

Za obradu eksperimentalnih podataka korišten je dodatak XLSTAT u MS Excel programu, te su parametri modela izračunati regresijskom analizom (model nultog reda linearnom, a model prvog reda i logistički sinusoidalni model nelinearnom regresijom). Određivanje vrijednosti parametara kinetičkih modela provedena je u svrhu predviđanja razvoja boje čajnog peciva i determiniranje potrebnog vremena pečenja proizvoda.

Uspješnost aproksimacije eksperimentalni podataka promjene boje matematičkim modelima procijenjena je na osnovi više statističkih kriterija:

➤ koeficijenta determinacije,  $R^2$

➤ srednje kvadratnog odstupanje,  $RMSE = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (L_{pre,i}^* - L_{eks,i}^*)^2}$

Aproksimacija eksperimentalnih podataka modelom je bolja što su vrijednosti srednjeg kvadratnog odstupanja niže ( $RMSE \rightarrow 0$ ), a koeficijenta determinacije više ( $R^2 \rightarrow 1$ ).

Nakon izmjerenih parametara boje, a za potrebe modeliranja, vrijednosti parametara boje CIE  $L^*a^*b^*$  sustava su izražene pomoću slijedećih koeficijenata:

### **Ukupna promjena boje (CIE76, 1976)**

Ukupna razlika boja prema CIE 1976. ( $\Delta E$ ) izračunava se slijedećom formulama **(13-16)**:

$$\Delta E = [(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2]^{1/2} \quad (13)$$

$$\Delta L^* = L_1^* - L_2^* \quad (14)$$

$$\Delta a^* = a_1^* - a_2^* \quad (15)$$

$$\Delta b^* = b_1^* - b_2^* \quad (16)$$

gdje se veličine  $L_1^*, a_1^*, b_1^*$  odnose na boju kojoj se mjeri odstupanje (uzorak), a veličine  $L_2^*, a_2^*, b_2^*$  na referentnu boju (standard).

Prema konvenciji, pozitivne vrijednosti pojedinih razlika  $\Delta L^*, \Delta a^*, \Delta b^*$ , znače da uzorak ima više te varijable nego standard. Na primjer, ako je razlika u svjetlini pozitivna vrijednost ( $\Delta L^* > 0$ ) to znači da je uzorak svjetliji od standarda, i obrnuto [CIE 1976].

Koliko je to odstupanje u boji vidljivo/uočljivo za promatrača opisali su Mokrzycki i sur., (2012) kako slijedi

$0 < \Delta E < 1$     promatrač ne vidi razliku

$1 < \Delta E < 2$     razliku boja primjećuje iskusni promatrač

$2 < \Delta E < 3,5$     razliku boja primjećuje i neiskusni promatrač

$3,5 < \Delta E < 5$     jasno uočljiva razlika boja

$5 < \Delta E$     promatrač uočava dvije različite boje

**Indeks posmeđivanja (*Browning Index*) (Buera i sur., 1986):**

$$BI = \frac{100(x - 0,31)}{0,172} \quad (17)$$

gdje je:

$$x = \frac{(a + 1,75L)}{(5,645L + a - 0,012b)} \quad (18)$$

**Indeks gubitka svjetline**

$$100 - L \quad (19)$$

**Indeks saturacije (*Saturation Index*) (Judd i Wyszecki, 1963):**

$$SI = \sqrt{a^2 + b^2} \quad (20)$$

**Indeks tamnjenja (*Darkening Index*):**

$$DI = 100 - WI \quad (21)$$

gdje je WI – Indeks bjeline (*Whiteness Index*) (Kasim i sur., 2014):

$$WI = \sqrt{(100 - L^2) + a^2 + b^2} \quad (22)$$

**Indeks boje pečenja (*Baking Colour Index*):**

$$BCI = \frac{(100 - L) + \frac{256 + a + b}{2,56}}{3} \quad (23)$$

### 3.3.3. Statistička obrada rezultata

Rezultati mjerenja boje prikazani su kao CIEL\*a\*b\* parametri boje te kao ukupna promjena boje ili kolorimetrijska razlika ( $\Delta E$ ) između dvije boje u CIE sustavu (referentnog i uspoređivanog), zatim kao indeks posmeđivanja (BI), indeks gubitka svjetline ( $100-L$ ), indeks saturacije (SI), indeks tamnjenja (DI) te indeks boje pečenja (BCI). Detaljan opis izračuna navedenih indeksa boje dan formulama (13-23).

Dobiveni rezultati su prikazani kao srednja vrijednost  $\pm$  standardna devijacija. Analiza varijance (ANOVA) i Fisher-ov LSD test najmanje značajne razlike (engl. *Least significant difference*) provedeni su upotrebom dodatka XLSTAT unutar MS Excel programa (Addinsoft, NewYork, SAD).

## **4. REZULTATI I RASPRAVA**

U ovom diplomskom radu prikazani su rezultati ispitivanja utjecaja zamjene dijela pšeničnog brašna tropom grožđa sorte Cabernet Sauvignon na parametre boje čajnog peciva. Ispitivanje se provodilo s dodacima tropa grožđa u udjelima 10%, 20% i 30%, a navedene smjese su se koristile za izradu čajnog peciva prema standardnoj AACC metodi 10- 50D. Boja uzoraka čajnog peciva određena je nedestruktivnom indirektnom metodom - računalnom analizom slike.

Mjereni parametri ( $L^*$ ,  $a^*$ ,  $b^*$ ) CIEL $^*a^*b^*$  modela boje poslužili su za izračunavanje različitih indeksa boje: ukupne promjene boje ( $\Delta E$ ), indeksa posmeđivanja (BI), indeksa gubitka svjetline ( $100-L$ ), indeksa saturacije (SI), indeksa tamnjenja (DI) te indeksa boje pečenja (BCI). Izračunati indeksi boje korišteni su u postupku matematičkog modeliranja.

Eksperimentalni podaci mjerenja boje čajnog peciva kontrolnog uzorka (čisto pšenično brašno) te uzoraka s dodatkom tropa grožđa sorte Cabernet Sauvignon u udjelima od 10, 20 i 30% sirovog tijesta ( $t_0$ ) te čajnog peciva pečenog tijekom 10 minuta ( $t_{10}$ ) prikazani su tablično **Tablica 7** i grafički **Slikama 12-14** kao parametri CIEL $^*a^*b^*$  sustava boja. Nadalje, rezultati mjerenja boje čajnog peciva prikazani su tablično (**Tablica 8**) i grafički kao vrijednosti ukupne promjene boje ( $\Delta E$ ) (**Slika 15**), indeks gubitka svjetline ( $100-L$ ) (**Slika 19**), indeks posmeđivanja (BI) (**Slika 23**), indeks saturacije (SI) (**Slika 27**), indeks tamnjenja (DI) (**Slika 31**), te indeks boje pečenja (BCI) (**Slika 35**).

U **Tablicama 7-8** prikazan je utjecaj udjela dodatka tropa grožđa (0%, 10%, 20% i 30%) na parametre boje ( $L^*$ ,  $a^*$ ,  $b^*$ ) te izračunate indekse boje ( $\Delta E$ ,  $100-L$ , BI, SI, DI i BCI) mjerene računalnom analizom slike. Prikazani podaci su srednja vrijednost  $\pm$  standardna devijacija; vrijednosti označene istim slovima nisu statistički značajno različite ( $p < 0,05$ ) prema Fisher-ovom LSD testu najmanje značajne razlike.

Parametri boje CIEL $^*a^*b^*$  sustava preračunate su u navedene indekse kako bi se mogao ispitati ukupni doprinos promjene boje uzoraka istovremeno za sva tri parametra boje  $L^*$ ,  $a^*$ , i  $b^*$ . Rezultati matematičkog modeliranja promjene boje čajnog peciva prikazani su tablično (**Tablica 19**) te grafički **Slikama 16-18, 20-22, 24- 26, 28-30, 32-34 i 36-38** za sve promatrane indekse boje ( $\Delta E$ ,  $100-L$ , BI, SI, DI i BCI).




## 4.1. REZULTATI MJERENJA BOJE ČAJNOG PECIVA RAČUNALNOM ANALIZOM SLIKE


Tijekom pečenja na površini čajnog peciva dolazi do nastanka poželjne smeđe boje koja je rezultat toplinskih procesa u tijestu kao što su neenzimsko posmeđivanje (Maillardove reakcije između šećera i proteina te karamelizacija, proces degradacije šećera uslijed djelovanja povišene temperature). Smeđa boja potječe i od netopivog smeđeg pigmenta melanoidina. Boja čajnog peciva prvo je što potrošač primijeti prilikom odabira te je glavni cilj proizvođača dobiti proizvod koji će imati odgovarajuću i što ujednačeniju boju. Iz tog razloga razvile su se brojne metode određivanja boje na osnovu kojih bi se mogao kontrolirati proces pečenja kako bi se taj cilj postigao. Razlikuju se direktne metode, usmjerene na kvantitativno praćenje produkata Maillardovih reakcija i karamelizacije, i indirektne, zasnovane na principu mjerenja reflektirane količine svjetlosti s površine analiziranog uzorka različitim mjernim uređajima poput računalne analize slike. U ovom radu boja čajnog peciva mjerena je primjenom računalne analize slike, indirektne nedestruktivne metode.

### 4.1.1. Promjena parametara boje CIEL $a^*b^*$ sustava boja čajnog peciva tijekom pečenja


U **Tablici 7** te na **Slikama 12-14** prikazane su izmjerene vrijednosti parametara boje CIEL  $a^*b^*$  modela boja te izračunate vrijednosti ukupne promjene boje čajnog peciva od pšeničnog brašna te s varijacijom udjela tropa grožđa sorte Cabernet Sauvignon, na početku pečenja (sirovo tijesto), nakon 10 minuta pečenja te razliku od 0. do 10. minute pečenja za sve ispitane uzorke. Prikazani podaci su srednja vrijednost  $\pm$  standardna devijacija; vrijednosti označene istim slovima nisu statistički značajno različite ( $p < 0,05$ ) prema Fisher-ovom LSD testu najmanje značajne razlike.



**Slika 12.** Promjena svjetline čajnog peciva tijekom pečenja



**Slika 13.** Promjena kromatske komponente zeleno-crvene boje čajnog peciva tijekom pečenja



**Slika 14.** Promjena kromatske komponente žuto-plave boje čajnog peciva tijekom pečenja

**Tablica 7.** Vrijednosti parametara boje čajnog peciva od pšeničnog brašna te s dodatkom tropa grožđa sorte Cabernet Sauvignon tijekom pečenja

	Udio tropa (%)	$L^*$	$a^*$	$b^*$	$\Delta E$
$t_0$	0	75,11± 0,11 <sup>a</sup>	-1,90± 0,22 <sup>d</sup>	17,87± 0,38 <sup>a</sup>	
	10	41,12± 0,20 <sup>b</sup>	0,24± 0,06 <sup>c</sup>	7,05± 0,00 <sup>b</sup>	
	20	29,57± 0,41 <sup>c</sup>	1,25± 0,03 <sup>b</sup>	5,72± 0,00 <sup>c</sup>	
	30	24,77± 0,34 <sup>d</sup>	2,45± 0,09 <sup>a</sup>	3,33± 0,08 <sup>d</sup>	
$t_{10}$	0	40,96± 0,34 <sup>a</sup>	10,34± 0,06 <sup>a</sup>	32,44± 0,14 <sup>a</sup>	39,10± 0,40 <sup>a</sup>
	10	29,39± 0,41 <sup>b</sup>	5,81± 0,07 <sup>b</sup>	13,72± 0,12 <sup>b</sup>	14,60± 0,30 <sup>b</sup>
	20	27,07± 0,04 <sup>c</sup>	5,18± 0,13 <sup>c</sup>	10,49± 0,08 <sup>c</sup>	6,68± 0,04 <sup>c</sup>
	30	21,66± 0,13 <sup>d</sup>	5,30± 0,03 <sup>c</sup>	8,16± 0,06 <sup>d</sup>	6,37± 0,17 <sup>c</sup>
$\Delta t$	0	-34,15± 0,25 <sup>d</sup>	12,24± 0,20 <sup>a</sup>	14,58± 0,41 <sup>a</sup>	39,10± 0,40 <sup>a</sup>
	10	-11,72± 0,30 <sup>c</sup>	5,57± 0,03 <sup>b</sup>	6,68± 0,12 <sup>b</sup>	14,60± 0,30 <sup>b</sup>
	20	-2,50± 0,38 <sup>a</sup>	3,93± 0,12 <sup>c</sup>	4,77± 0,08 <sup>c</sup>	6,68± 0,04 <sup>c</sup>
	30	-3,11± 0,21 <sup>b</sup>	2,85± 0,06 <sup>d</sup>	4,83± 0,04 <sup>c</sup>	6,37± 0,17 <sup>c</sup>

Dobiveni rezultati ukazuju na postojanje statistički značajne razlike između kontrolnog uzorka (uzorak od pšeničnog brašna) te uzoraka s dodatkom tropa grožđa od 10, 20 i 30% za gotovo sve parametre boje CIEL  $a^*b^*$  sustava. Vrijednosti svjetline bile su najveće kod kontrolnog uzorka, dok su se smanjivale s povećanjem udjela tropa grožđa. Najveće vrijednosti svjetline izmjerene su kod sirovog tijesta, a najmanje kod uzoraka s dodatkom tropa grožđa 30% nakon 10. minute pečenja. Za doprinos tamnijoj boji uzoraka s dodatkom tropa grožđa zaslužni su pigmenti prisutni u tropu grožđa. Vrijednosti svjetline kretale su se u rasponu 24,77- 75,11 kod sirovog tijesta, odnosno 21,66-40,96 kod uzoraka pečenih 10 minuta.

Vrijednosti kromatske komponente zeleno-crvene boje  $a^*$  kretale su se u rasponu 1,90-2,45 kod sirovog tijesta, odnosno 5,30-10,34 kod uzoraka pečenih 10 minuta. Veće vrijednosti parametra  $a^*$  ukazuju na intenzivnije crveno obojenje, odnosno uzorci se nalaze u domeni crvene boje. Vrijednosti kromatske komponente žuto-plave boje  $b^*$  kretale su se u rasponu 3,33-17,87 za sirovo tijesto, odnosno 8,16-32,44 kod uzoraka pečenih 10 minuta. Veće vrijednosti parametra  $b^*$  ukazuju na prisutnost žute boje, odnosno uzorci se nalaze u domeni žute boje.

Vrijednosti ukupne promjene boje kretale su se u rasponu 6,37-39,10 te su veće razlike uočene

kod uzoraka pšeničnog brašna nego kod dodatka tropa grožđa. Što je i logično, jer kod doprinosa ukupnoj promjeni boje doprinose i pigmenti prisutni u tropu grožđa pa se obojenje površine uslijed Maillardovih reakcija i karamelizacije teže uočava. Nadalje, prema vrijednostima ukupne promjene boje nema statistički značajne razlike između uzoraka s dodatkom 20 i 30% tropa grožđa. To znači da je promjenu boje teže uočiti što je udio pigmenta preko dodatka tropa grožđa veći.

Razlika između promatranih parametara boje sirovih uzoraka i uzoraka pečenih nakon 10 minuta prikazana je kao  $\Delta t$ . Prema dobivenim rezultatima vidljivo je da postoji statistički značajna razlika između sirovih i pečenih kontrolnih uzoraka (uzorci od pšeničnog brašna) i uzoraka s dodatkom tropa grožđa za gotovo sve promatrane parametre boje CIEL\*a\*b\* sustava te vrijednostima ukupne promjene boje. Odstupanja od ove tvrdnje pokazuju uzorci s većim udjelima tropa grožđa (20 i 30%) među kojima ne postoji statistički značajna razlika, odnosno ukupna promjena boje nije uočljiva među njima. Ako se uzme u obzir da pri većim udjelima dodatka tropa grožđa čajno pecivo ima i više pigmenata prisutnih u samom dodatku, tada je manja razlika u promjeni boje između ovih uzoraka logična.

**Tablica 8.** Vrijednosti izračunatih parametara boje čajnog peciva od pšeničnog brašna s dodatkom tropa grožđa sorte Cabernet Sauvignon tijekom pečenja

	Udio tropa (%)	100-L	BI	SI	DI	BCI
$t_0$	0	24,89±0,11 <sup>d</sup>	24,27±0,86 <sup>a</sup>	17,97±0,36 <sup>a</sup>	30,70±0,23 <sup>d</sup>	43,71±0,09 <sup>d</sup>
	10	58,88±0,20 <sup>c</sup>	18,59±0,19 <sup>c</sup>	7,05±0,00 <sup>b</sup>	59,30±0,20 <sup>c</sup>	53,91±0,07 <sup>c</sup>
	20	70,43±0,41 <sup>b</sup>	23,90±0,45 <sup>a</sup>	5,85±0,01 <sup>c</sup>	70,67±0,41 <sup>b</sup>	57,72±0,14 <sup>b</sup>
	30	75,23±0,34 <sup>a</sup>	21,10±0,85 <sup>b</sup>	4,13±0,11 <sup>d</sup>	75,35±0,34 <sup>a</sup>	59,16±0,13 <sup>a</sup>
$t_{10}$	0	59,04±0,34 <sup>d</sup>	151,33±2,98 <sup>a</sup>	34,05±0,14 <sup>a</sup>	68,16±0,36 <sup>d</sup>	58,58±0,14 <sup>d</sup>
	10	70,61±0,41 <sup>c</sup>	75,06±2,27 <sup>b</sup>	14,90±0,14 <sup>b</sup>	72,16±0,43 <sup>c</sup>	59,41±0,16 <sup>c</sup>
	20	72,93±0,04 <sup>b</sup>	61,53±0,88 <sup>c</sup>	11,70±0,12 <sup>c</sup>	73,86±0,06 <sup>b</sup>	59,68±0,04 <sup>b</sup>
	30	78,34±0,13 <sup>a</sup>	63,66±0,93 <sup>c</sup>	9,73±0,06 <sup>d</sup>	78,94±0,14 <sup>a</sup>	61,20±0,05 <sup>a</sup>
$\Delta t$	0	34,15±0,25 <sup>a</sup>	127,06±3,23 <sup>a</sup>	16,08±0,38 <sup>a</sup>	37,45±0,41 <sup>a</sup>	14,87±0,15 <sup>a</sup>
	10	11,72±0,30 <sup>b</sup>	56,48±2,11 <sup>b</sup>	7,85±0,14 <sup>b</sup>	12,86±0,32 <sup>b</sup>	5,50±0,12 <sup>b</sup>
	20	2,50±0,38 <sup>d</sup>	37,63±0,43 <sup>d</sup>	5,85±0,12 <sup>c</sup>	3,19±0,36 <sup>c</sup>	1,97±0,10 <sup>c</sup>
	30	3,11±0,21 <sup>c</sup>	42,56±0,37 <sup>c</sup>	5,60±0,06 <sup>c</sup>	3,60±0,21 <sup>c</sup>	2,04±0,08 <sup>c</sup>

U **Tablici 8.** prikazane su vrijednosti izračunatih indeksa boje na temelju izmjerenih vrijednosti parametara boje  $L^*$ ,  $a^*$  i  $b^*$ . Vrijednosti indeksa 100- $L$  kretale su se u rasponu 24,89-75,23 za sirove uzorke čajnog peciva, odnosno 59,04-78,34 za uzorke čajnog peciva pečene 10 minuta.

Rezultati statističke analize ukazuju na statističku značajnost među svim promatranim uzorcima. Vrijednosti indeksa 100- $L$  bile su veće kod pečenih uzoraka s dodatkom tropa grožđa te su proporcionalno rasle porastom udjela tropa grožđa. Prikazani podaci su srednja vrijednost  $\pm$  standardna devijacija; vrijednosti označene istim slovima nisu statistički značajno različite ( $p < 0,05$ ) prema Fisher-ovom LSD testu najmanje značajne razlike.

Vrijednosti indeksa BI kretale su se u rasponu 18,59-24,27 za sirove uzorke čajnog peciva, odnosno 61,53-151,33 za uzorke čajnog peciva pečene 10 minuta. Rezultati statističke analize ukazuju na statističku značajnost među gotovo svim promatranim uzorcima, a najveće vrijednosti BI bile su kod čajnog peciva od pšeničnog brašna (sirovog  $24,27 \pm 0,86$ , i pečenog  $151,33 \pm 2,98$ ).

Vrijednosti indeksa SI kretale su se u rasponu 4,13-17,97 za sirove uzorke čajnog peciva, odnosno 9,73-34,05 za uzorke čajnog peciva pečene 10 minuta. Rezultati statističke analize ukazuju na statističku značajnost među svim promatranim uzorcima. Vrijednosti SI bile su najveće kod kontrolnog uzorka (sirovog i pečenog), a porastom udjela tropa grožđa vrijednosti SI indeksa su opadale.


Vrijednosti indeksa DI kretale su se u rasponu 30,70-75,35 za sirove uzorke čajnog peciva, odnosno 68,16-78,94 za uzorke čajnog peciva pečene 10 minuta. Rezultati statističke analize ukazuju na statističku značajnost među gotovo svim promatranim uzorcima. Vrijednosti DI bile su najmanje kod kontrolnog uzorka (sirovog i pečenog), a porastom udjela tropa grožđa vrijednosti BI indeksa rasle.

Vrijednosti indeksa BCI kretale su se u rasponu 43,71-59,16 za sirove uzorke čajnog peciva, odnosno 58,58-61,20 za uzorke čajnog peciva pečene 10 minuta. Rezultati statističke analize ukazuju na statističku značajnost među gotovo svim promatranim uzorcima. Vrijednosti BCI bile su najmanje kod kontrolnog uzorka (sirovog i pečenog), a porastom udjela tropa grožđa vrijednosti BCI indeksa su rasle.


## 4.2. REZULTATI MATEMATIČKOG MODELIRANJA PROMJENE BOJE ČAJNOG PECIVA S DODATKOM TROPA GROŽĐA

### 4.2.1. Modeliranje ukupne promjene boje primjenom različitih matematičkih modela


Na Slici 15 prikazane su izračunate vrijednosti ukupne promjene boje uzoraka čajnog peciva od pšeničnog brašna (PB) te uzoraka s dodatkom tropa grožđa u udjelima od 10% (TG10), 20% (TG20) i 30% (TG30). Vrijednosti ukupne promjene boje rastu porastom vremena pečenja, te su najveće u 10. minuti pečenja. Uspoređujući vrijednosti ukupne promjene boje čajnog peciva od pšeničnog brašna i one s dodatkom tropa grožđa vidljivo je da uzorci s dodatkom tropa grožđa imaju manje uočljive razlike promjene boje, u odnosu na one bez dodatka.




**Slika 15.** Usporedba vrijednosti ukupne promjene boje čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa tijekom pečenja



**Slika 16.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti ukupne promjene boje čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (model nultog reda)



**Slika 17.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti ukupne promjene boje čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (model prvog reda)




**Slika 18.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti 100-L indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (logistički sinusoidalni model)


Na Slikama 16-18 prikazano je slaganje eksperimentalnih vrijednosti ukupne promjene boje, te onih predviđenih kinetičkim modelima nultog i prvog reda te logističkog sinusoidalnog modela. Izračunate vrijednosti parametara kinetičkih modela ukupne promjene boje uzoraka čajnog peciva dane su u Tablici 9, kao i statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka odabranim kinetičkim modelima.

#### 4.2.2. Modeliranje promjene indeksa gubitka svjetline (100-L) primjenom različitih matematičkih modela

Na Slici 19 prikazane su izračunate vrijednosti indeksa 100-L uzoraka čajnog peciva od pšeničnog brašna (PB) te uzoraka s dodatkom tropa grožđa u udjelima od 10% (TG10), 20% (TG20) i 30% (TG30). Vrijednosti promatranog indeksa boje za uzorke čajnog peciva od pšeničnog brašna (PB) rastu porastom vremena pečenja, te su najveće u 10. minuti pečenja za razliku od uzoraka s dodatkom tropa grožđa (20 i 30%) kod kojih se vrijednosti indeksa 100-L gotovo ne mijenjaju tijekom pečenja. Uspoređujući vrijednosti indeksa 100-L čajnog peciva od pšeničnog brašna i one s dodatkom tropa grožđa vidljivo je da uzorci s dodatkom tropa grožđa imaju manje uočljive razlike indeksa 100-L u odnosu na one bez dodatka.




**Slika 19.** Usporedba vrijednosti indeksa 100-L čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa tijekom pečenja




**Slika 20.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti 100-L indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (model nultog reda)





**Slika 21.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti 100-L indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (model prvog reda)




**Slika 22.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti 100-L indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (logistički sinusoidalni model)


Na Slikama 19-22 prikazano je slaganje eksperimentalnih vrijednosti indeksa 100-L boje, te onih predviđenih kinetičkim modelima nultog i prvog reda te logističkog sinusoidalnog modela. Izračunate vrijednosti parametara kinetičkih modela indeksa 100-L boje uzoraka čajnog peciva dane su u Tablici 9, kao i statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka odabranim kinetičkim modelima.

### 4.2.3. Modeliranje parametra posmeđivanja primjenom različitih matematičkih modela


Na Slici 23 prikazane su izračunate vrijednosti indeksa BI uzoraka čajnog peciva od pšeničnog brašna (PB) te uzoraka s dodatkom tropa grožđa u udjelima od 10% (TG10), 20% (TG20) i 30% (TG30). Vrijednosti promatranog indeksa boje za uzorke čajnog peciva od pšeničnog brašna (PB) rastu porastom vremena pečenja, te su najveće u 10. minuti pečenja za razliku od uzoraka s dodatkom tropa grožđa. Obzirom na rezultate BI indeksa moguće je zaključiti da je ovaj indeks boje neprikladan u slučaju usporedbe različitih uzoraka (onih s dodatkom i onih bez dodatka). On se može primijeniti u slučaju promatranja boje uzoraka čajnog peciva koji se ne razlikuju po vrsti dodataka.




**Slika 23.** Usporedba vrijednosti BI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa tijekom pečenja



**Slika 24.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti BI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (model nultog reda)



**Slika 25.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti BI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (model prvog reda)




**Slika 26.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti BI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (logistički sinusoidalni model)

Na Slikama 25-26 prikazano je slaganje eksperimentalnih vrijednosti BI indeksa, te onih predviđenih kinetičkim modelima nultog i prvog reda te logističkog sinusoidalnog modela. Izračunate vrijednosti parametara kinetičkih modela BI indeksa uzoraka čajnog peciva dane su u Tablici 9, kao i statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka odabranim kinetičkim modelima.


#### 4.2.4. Modeliranje indeksa saturacije/zasićenosti boje primjenom različitih matematičkih modela

Na Slici 27 prikazane su izračunate vrijednosti SI indeksa uzoraka čajnog peciva od pšeničnog brašna (PB) te uzoraka s dodatkom tropa grožđa u udjelima od 10% (TG10), 20% (TG20) i 30% (TG30). Vrijednosti promatranog SI indeksa boje za uzorke čajnog peciva rastu porastom vremena pečenja, te su najveće u 10. minuti pečenja.


Uspoređujući vrijednosti SI indeksa čajnog peciva od pšeničnog brašna i one s dodatkom tropa grožđa vidljivo je da uzorci s dodatkom tropa grožđa imaju manje razlike SI indeksa (od 0. do 10. minute pečenja) u odnosu na one bez dodatka.




**Slika 27** Usporedba vrijednosti SI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa tijekom pečenja



**Slika 28.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti SI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (model nultog reda)



**Slika 29.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti SI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (model prvog reda)




**Slika 30.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti SI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (logistički sinusoidalni model)


Na Slikama 27-30 prikazano je slaganje eksperimentalnih vrijednosti SI indeksa, te onih predviđenih kinetičkim modelima nultog i prvog reda te logističkog sinusoidalnog modela. Izračunate vrijednosti parametara kinetičkih modela SI indeksa uzoraka čajnog peciva dane su u Tablici 9, kao i statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka odabranim kinetičkim modelima.

#### 4.2.5. Modeliranje indeksa tamnjenja (DI) primjenom različitih matematičkih modela


Na Slici 31 prikazane su izračunate vrijednosti DI indeksa uzoraka čajnog peciva od pšeničnog brašna (PB) te uzoraka s dodatkom tropa grožđa u udjelima od 10% (TG10), 20% (TG20) i 30% (TG30). Vrijednosti promatranog indeksa boje za uzorke čajnog peciva od pšeničnog brašna (PB) rastu porastom vremena pečenja, te su najveće u 10. minuti pečenja za razliku od uzoraka s dodatkom tropa grožđa (20 i 30%) kod kojih se vrijednosti DI indeksa gotovo ne mijenjaju tijekom pečenja. Uspoređujući vrijednosti DI indeksa čajnog peciva od pšeničnog brašna i one s dodatkom tropa grožđa vidljivo je da uzorci s dodatkom tropa grožđa imaju manje uočljive razlike indeksa u odnosu na one bez dodatka.




**Slika 31.** Usporedba vrijednosti DI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa tijekom pečenja



**Slika 32.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti DI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (model nultog reda)



**Slika 33.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti DI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (model prvog reda)




**Slika 34** Slaganje eksperimentalnih i modelom predviđenih vrijednosti DI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (logistički sinusoidalni)


Na Slikama 31-34 prikazano je slaganje eksperimentalnih vrijednosti DI indeksa, te onih predviđenih kinetičkim modelima nultog i prvog reda te logističkog sinusoidalnog modela. Izračunate vrijednosti parametara kinetičkih modela DI indeksa uzoraka čajnog peciva dane su u Tablici 9, kao i statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka odabranim kinetičkim modelima.

#### 4.2.6. Modeliranje BCI indeksa boje primjenom različitih matematičkih modela

Na Slici 35 prikazane su izračunate vrijednosti BCI indeksa uzoraka čajnog peciva od pšeničnog brašna (PB) te uzoraka s dodatkom tropa grožđa u udjelima od 10% (TG10), 20% (TG20) i 30% (TG30). Vrijednosti promatranog indeksa boje za uzorke čajnog peciva od pšeničnog brašna (PB) rastu porastom vremena pečenja, te su najveće u 10. minuti pečenja za razliku od uzoraka s dodatkom tropa grožđa (20 i 30%) kod kojih se vrijednosti BCI indeksa gotovo ne mijenjaju tijekom pečenja.




**Slika 35.** Usporedba vrijednosti BCI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa tijekom pečenja




**Slika 36.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti BCI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (model nultog reda)





**Slika 37.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti BCI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (model prvog reda)



**Slika 38.** Slaganje eksperimentalnih i modelom predviđenih vrijednosti BCI indeksa čajnog peciva od pšeničnog brašna i različitih udjela tropa grožđa (logistički sinusoidalni model)

Na Slikama 36-38 prikazano je slaganje eksperimentalnih vrijednosti BCI indeksa, te onih predviđenih kinetičkim modelima nultog i prvog reda te logističkog sinusoidalnog modela. Izračunate vrijednosti parametara kinetičkih modela BCI indeksa uzoraka čajnog peciva dane su u Tablici 9, kao i statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka odabranim kinetičkim modelima.

#### 4.2.7. Određivanje parametara matematičkih modela te procjena aproksimacije eksperimentalnih podataka matematičkim modelima

Uspješnost primjene odabranih matematičkih modela analizirana je na osnovi više statističkih kriterija. U ovom radu prikazani su koeficijent determinacije ( $R^2$ ), koji bi idealnom slučaju imao vrijednost 1, te srednje kvadratno odstupanje (RMSE). Modeliranje kinetike promjene boje ima važnu ulogu u dizajniranju procesa budući da daje nužne informacije o parametrima modela poput brzine reakcije ili nastajanju određenih promjena kao funkcije procesnih varijabli (temperature, vremena).

**Tablica 9.** Parametri matematičkih modela te statistički kriteriji uspješnosti aproksimacije eksperimentalnih podataka odabranim kinetičkim modelima

	Udio tropa (%)	0. red				1. red				Logistički sinusoidalni model			
		$k$ ( $\text{min}^{-1}$ )	$t_{1/2}$ (min)	$R^2$	RMSE	$k$ ( $\text{min}^{-1}$ )	$t_{1/2}$ (min)	$R^2$	RMSE	$k$ ( $\text{min}^{-1}$ )	$t_{1/2}$ (min)	$R^2$	RMSE
$\Delta E$	0	0,097	5,18	0,954	0,090	0,154	4,51	0,857	0,166	0,642	5,66	<b>0,970</b>	<b>0,080</b>
	10	0,116	4,30	0,910	0,148	0,280	2,48	<b>0,983</b>	<b>0,050</b>	0,595	3,11	0,947	0,100
	20	0,110	4,56	0,928	0,116	0,202	3,44	0,881	0,169	0,928	4,58	<b>0,981</b>	<b>0,069</b>
	30	0,111	4,52	0,961	0,083	0,214	3,24	0,944	0,119	0,752	4,17	<b>0,997</b>	<b>0,028</b>
100-L	0	0,095	5,28	0,935	0,119	0,145	4,78	0,829	0,193	0,794	5,95	<b>0,983</b>	<b>0,067</b>
	10	0,115	4,35	0,875	0,170	0,282	2,46	<b>0,950</b>	<b>0,081</b>	0,506	3,05	0,889	0,137
	20	0,107	4,69	<b>0,966</b>	<b>0,089</b>	0,213	3,26	0,964	0,069	0,469	4,07	0,946	0,094
	30	0,093	5,36	0,968	0,085	0,144	4,83	0,870	0,164	0,644	5,89	<b>0,986</b>	<b>0,055</b>
BI	0	0,081	6,19	0,887	0,147	0,111	6,23	0,776	0,202	0,755	6,97	<b>0,977</b>	<b>0,073</b>
	10	0,110	4,54	0,941	0,102	0,212	3,27	0,930	0,131	0,714	4,11	<b>0,967</b>	<b>0,088</b>
	20	0,107	4,68	0,915	0,135	0,185	3,74	0,851	0,197	1,186	4,87	<b>0,990</b>	<b>0,056</b>
	30	0,108	4,63	0,968	0,074	0,198	3,50	0,932	0,132	0,745	4,46	<b>0,997</b>	<b>0,027</b>
SI	0	0,097	5,13	<b>0,939</b>	<b>0,095</b>	0,173	4,02	0,894	0,111	0,398	4,90	0,899	0,122
	10	0,118	4,22	0,823	0,196	0,259	2,68	0,869	0,185	2,093	3,41	<b>0,990</b>	<b>0,069</b>
	20	0,109	4,58	0,892	0,155	0,193	3,59	0,833	0,212	1,473	4,79	<b>0,990</b>	<b>0,059</b>
	30	0,115	4,35	0,930	0,115	0,235	2,95	0,936	0,129	0,895	3,86	<b>0,999</b>	<b>0,021</b>
DI	0	0,096	5,23	0,955	0,089	0,151	4,59	0,857	0,164	0,625	5,73	<b>0,969</b>	<b>0,081</b>
	10	0,115	4,34	0,896	0,158	0,278	2,49	<b>0,968</b>	<b>0,066</b>	0,535	3,11	0,916	0,121
	20	0,107	4,69	<b>0,983</b>	<b>0,061</b>	0,204	3,39	0,958	0,084	0,531	4,31	0,973	0,070
	30	0,096	5,22	0,980	0,069	0,152	4,57	0,889	0,155	0,636	5,64	<b>0,991</b>	<b>0,045</b>
BCI	0	0,096	5,23	0,950	0,100	0,150	4,64	0,849	0,176	0,704	5,79	<b>0,980</b>	<b>0,069</b>
	10	0,115	4,35	0,927	0,132	0,264	2,62	<b>0,980</b>	<b>0,057</b>	0,577	3,31	0,951	0,096
	20	0,108	4,63	0,964	0,077	0,201	3,46	0,923	0,129	0,692	4,49	<b>0,985</b>	<b>0,056</b>
	30	0,104	4,81	0,989	0,044	0,182	3,80	0,933	0,126	0,646	4,81	<b>0,996</b>	<b>0,032</b>

Rezultati u **Tablici 9.** prikazuju izračunate parametre kinetičkih modela (nultog i prvog reda, te logističkog sinusoidalnog modela), te statističke kriterije uspješnosti primjene analiziranih matematičkih modela za predviđanje boje čajnog peciva kontrolnih uzoraka (od čistog pšeničnog brašna) i uzoraka s dodatkom tropa grožđa (u udjelima od 10, 20 i 30%).

Kod uzoraka čajnog peciva **od pšeničnog brašna** rezultati kinetičkih modela pokazali su da je koeficijent determinacije ( $R^2$ ) najveći (odnosno najbliži idealnoj vrijednosti 1) uz najmanje srednje kvadratno odstupanje (RMSE) kod logističkog sinusoidalnog modela za promatrane varijable  $\Delta E$ , 100-L, BI, DI i BCI; odnosno kinetičkog modela nultog reda za varijablu SI.

Kod uzoraka čajnog peciva **s dodatkom 10% tropa grožđa** rezultati kinetičkih modela pokazali su da je koeficijent determinacije ( $R^2$ ) najveći uz najmanje srednje kvadratno odstupanje (RMSE) kod kinetičkog modela prvog reda za promatrane varijable  $\Delta E$ , 100-L, DI i BCI; odnosno logističkog sinusoidalnog modela za varijable BI, SI.

Kod uzoraka čajnog peciva **s dodatkom 20% tropa grožđa** rezultati kinetičkih modela pokazali su da je koeficijent determinacije ( $R^2$ ) najveći uz najmanje srednje kvadratno odstupanje (RMSE) kod logističkog sinusoidalnog modela za varijable  $\Delta E$ , BI, SI, BCI; odnosno kinetičkog modela nultog reda za 100-L i DI varijable.

Kod uzoraka čajnog peciva **s dodatkom 30% tropa grožđa** rezultati kinetičkih modela pokazali su da je koeficijent determinacije ( $R^2$ ) najveći uz najmanje srednje kvadratno odstupanje (RMSE) kod logističkog sinusoidalnog modela za sve promatrane varijable modela ( $\Delta E$ , 100-L, BI, SI, DI i BCI).

## **5. ZAKLJUČCI**

U radu je ispitan utjecaj zamjene dijela pšeničnog brašna tropom grožđa sorte Cabernet Sauvignon u udjelima od 10, 20 i 30% na parametre boje čajnog peciva: svjetline  $L^*$ , parametra boje  $a^*$ , parametra boje  $b^*$ , ukupne promjene boje  $\Delta E$ , indeksa posmeđivanja  $BI$ , indeksa gubitka svjetline  $100-L$ , indeksa saturacije  $SI$ , indeksa tamnjenja  $DI$ , te indeksa boje pečenja  $BCI$ . S ciljem predviđanja i kontrole razvoja boje čajnog peciva tijekom pečenja, boja uzoraka mjerena je računalnom analizom slike kao količina reflektirane svjetlosti sa površine uzoraka, te su rezultati prikazani kao parametri CIEL  $a^*b^*$  sustava boja.

Dobivene vrijednosti parametara boje kao ispitivane varijable korištene su u postupku matematičkog modeliranja za koje su izračunati parametri kinetičkih modela (nultog i prvog reda, te logističkog sinusoidalnog modela), a prikladnost ispitanih matematičkih modela za predviđanje promjene boje čajnog peciva kontrolnih uzoraka (od čistog pšeničnog brašna) i uzoraka s dodatkom tropa grožđa (u udjelima od 10, 20 i 30%) uzoraka provjerena je pomoću statističkih kriterija uspješnosti primjene analiziranih matematičkih modela  $R^2$  i RMSE. Na temelju dobivenih rezultata moguće je zaključiti sljedeće:

- dodatak tropa grožđa kao i varijacija u udjelima imaju statistički značajan utjecaj na sve parametre boje ( $L^*$ ,  $a^*$ ,  $b^*$ ) čajnog peciva kako sirovog tako i pečenih uzoraka čajnog peciva
- različit udio dodatka tropa grožđa statistički značajno utječe na **promjenu svjetline** uzoraka čajnog peciva. Uzorci čajnog peciva od pšeničnog brašna imaju veće vrijednosti parametra svjetline u odnosu na one s dodatkom tropa grožđa ( $75,11 \pm 0,11$  kod sirovog tijesta, te  $40,96 \pm 0,34$  kod pečenih uzoraka) te su oni svjetliji u odnosu na one s dodatkom tropa grožđa (za sirovo tijesto:  $41,12 \pm 0,20$  s dodatkom 10% tropa grožđa,  $29,57 \pm 0,41$  s dodatkom 20% tropa grožđa,  $24,77 \pm 0,34$  s dodatkom 30% tropa grožđa; a kod pečenih uzoraka:  $29,39 \pm 0,41$  s dodatkom 10% tropa grožđa,  $27,07 \pm 0,04$  s dodatkom 20% tropa grožđa,  $21,66 \pm 0,13$  s dodatkom 30% tropa grožđa).
- različit udio dodatka tropa grožđa statistički značajno utječe na promjenu **kromatske komponente zeleno-crvene boje ( $a^*$ )** uzoraka čajnog peciva. Vrijednosti parametara boje  $a$  bile su pozitivne kod svih uzoraka, osim kod sirovog tijesta od čistog pšeničnog brašna. Povećanjem udjela dodatka tropa grožđa rastu i vrijednosti parametara boje  $a$ , što ukazuje na činjenicu da se uzorci nalaze više u domeni crvene boje.
- različit udio dodatka tropa grožđa statistički značajno utječe na promjenu **kromatske komponente plavo-žute boje ( $b^*$ )** uzoraka čajnog peciva. Vrijednosti parametara boje  $b$  bile su pozitivne kod svih uzoraka, te su najveće kod uzoraka bez dodatka tropa

grožđa. Povećanjem udjela dodatka tropa grožđa vrijednosti parametra boje  $b$  opadaju što ukazuje na činjenicu da se uzorci s većim udjelom tropa grožđa nalaze više u domeni plave boje

- **ukupna promjena boje  $\Delta E$** , bila je jasno uočljiva za ljudsko oko (u rasponu 6,37 – 39,10) te je ovisila o udjelu dodatka tropa grožđa (pri većim vrijednostima udjela dodatka tropa, manje su uočljive razlike u ukupnoj promjeni boje). Uspoređujući uzorke bez i s dodatkom tropa grožđa, vidljivo je da postoji statistički značajna razlika između uzoraka od pšeničnog brašna te onih s dodatkom tropa grožđa od 10%, dok se uzorci s dodatkom tropa grožđa od 20 i 30% nisu statistički značajno razlikovali
- prema rezultatima promatranih indeksa boje (indeksa gubitka svjetline **100-L**, indeksa saturacije **SI**, indeksa tamnjenja **DI**, te indeksa boje pečenja **BCI**) postoji statistički značajna razlika između uzoraka s dodatkom tropa grožđa te onih od čistog pšeničnog brašna (kako za tijesto tako i kod pečenih uzoraka čajnog peciva). Indeks posmeđivanja **BI**, pokazuje odstupanje od ovog zaključka budući da je ovaj parametar neprikladan za uspoređivanje različitih uzoraka (odnosno onih sa i bez različitih dodataka)
- nakon provedenog matematičkog modeliranja model koji se pokazao najprikladniji za predviđanje promjene boje ispitanih uzoraka čajnog peciva tijekom pečenja bio je **logistički sinusoidalni model**. Odstupanja od ovog zaključka pokazali su slijedeći ispitani indeksi boje analiziranih uzoraka čajnog peciva:
  - za predviđanje promjene boje uzoraka čajnog peciva od pšeničnog brašna pomoću **SI** indeksa boje najboljim se pokazao **kinetički model nultog reda**
  - za predviđanje promjene boje uzoraka čajnog peciva s dodatkom 10% tropa grožđa pomoću  **$\Delta E$ , 100-L, DI i BCI** indeksa boje najboljim se pokazao **kinetički model prvog reda**
  - za predviđanje promjene boje uzoraka čajnog peciva s dodatkom 20% tropa grožđa pomoću **100-L i DI** indeksa boje najboljim se pokazao **kinetički model nultog reda**

## **6. LITERATURA**

**AACCI Method** 10-50.05, Baking Quality of Cookie Flour, Approved Methods of Analysis, 11th Edition.

**Acun S, Gül H:** Effects of grape pomace and grape seed flours on cookie quality. *Quality Assurance and Safety of Crops & Foods*, 6(1): 81-88 Wageningen Academic, 2014.

**Brosnan T, Sun DW:** *Improving quality inspection of food products by computer vision-a review*. Journal of Food Engineering, 2004.

**Bucić-Kojić A, Planinić M, Tomas S, Tišma M:** Trop grožđa – otpad i visokovrijedna sirovina. Neke mogućnosti iskorištenja nusproizvoda prehrambene industrije. Prehrambeno-tehnološki fakultet Osijek, Osijek, 2017.

**Buera MP, Lozano RD, Petriella C:** Definition of colour in the non enzymatic browning process. *Die Farbe* 32/33:318-322, 1986.

**Filko D:** Robusna lokalizacija mobilnog robota zasnovana na vizualnim obilježjima ravninskih segmenata. *Doktorska disertacija*. Elektrotehnički fakultet, Osijek, 2013.

**Gavrilović M:** Tehnologija konditorskih proizvoda. Zavod za izdavanje udžbenika Novi Sad, 2011.

**Gokmen V, Acar OC, Arribas-Lorenzo G, Morales FJ:** *Investigating the correlation between acrylamide content and browning ratio of model cookies*. Journal of Food Engineering, 2008.

**Hoseney RC:** *Principles of cereal science and technology*, AACC, Inc. St. Paul Minnesota, USA, 1994.

**Judd DB, Wyszecki G:** *Color in Business, Science and Industry*. John Wiley & Sons, New York, 1963.

**Kasim R, Mehmet UK:** *Biochemical changes and color properties of fresh-cut green bean (Phaseolus vulgaris L. cv.gina) treated with calcium chloride during storage*. Food Science and Technology, 35(2): 266-272, 2015.

**Kent NL, Evers AD:** *Technology of cereals*. Elsevier Science Ltd., UK, 1994.

**Larrain RE, Schaefer DM, Reed JD:** *Use of digital images to estimate CIE color coordinates of beef*. Food Research International. 41:380–385, 2008.

**Leon K, Mery D, Pedreschi D, Leon D:** Color measurement in L\*a\*b\* units from RGB digital images. Food Research International, 39: 1084-1091, 2006.

**Lukinac-Čačić J:** Matematičko modeliranje i optimiranje kinetike promjene boje kruha tijekom pečenja. *Doktorski rad*. Prehrambeno-tehnološki fakultet, Osijek, 2012.

**Magdić D, Horvat D, Drezner G, Jurković Z, Šimić G:** *Image analysis of bread crumb structure in relation to gluten strength of wheat*. Poljoprivreda, 2006.

**Manley DJR:** Technology of Biscuits, Crackers and Cookies, 3rd edition. Woodhead Publishing, Cambridge 2000.



**Mendoza F, Dejmek P, Aguilera JM:** Calibrated color measurements of agricultural foods using image analysis. *Postharvest Biology and Technology*, 41(3): 285-295, 2006.

**Mokrzycki WS, Tatol M:** Color difference Delta E - A survey. *Machine Graphics and Vision*, 20(4): 383-411, 2011.

**Pedreschi F, Bustos O, Mery D, Moyano P, Kaack K, Granby K:** *Color kinetics and acrylamide formation in NaCl soaked potato chips*. *Journal of Food Engineering*, 2007b.

**Puglia S:** *Technical Primer U Handbook for Digital Projects: A Management Tool for Preservation and Access* Maxine K. Sitts.(ur.) Northeast Document Conservation Center, 2000.

**Purlis E, Salvadori VO:** *Bread browning kinetics during baking*. *Journal of Food Engineering*, 2007.

**Ramírez-Jiménez A, Guerra-Hernández E, García-Villanova B:** *Browning indicators in bread*. *Journal of Agricultural and Food Chemistry*, 2000.

**Ridler TW, Calvard S:** Picture thresholding using an iterative selection method. *IEEE Transactions on Systems, Man and Cybernetics*, 8(8): 630-632, 1978.

**Ureta MM, Olivera DF, Salvadori V:** Quality attributes of muffins: effect of baking operative condition. *Food and Bioprocess Technology* 7:463–470, 2014.

**Wahlby U, Skjöldebrand C.** *Reheating characteristics of crust formed on buns, and crust formation*. *Journal of Food Engineering*, 2002.

**Web (1):** Čajno pecivo. URL: <https://www.gourmandize.com/recipe-55093-tea-biscuits.htm> [datum pristupa: 14.11.2018.].

**Web (2):** Kromatske boje. URL: <http://theeverylastdetail.com/fashion-friday-making-different-bridesmaids-dresses-look-polished/> [datum pristupa: 14.11.2018.].

**Web (3):** Akromatske boje. URL: <https://media-x.hr/akromatske-boje-2/> [datum pristupa: 14.11.2018.].

**Web (4):** Svjetlina boje. URL: <https://media-x.hr/svjetlina-boje-2/> [datum pristupa: 14.11.2018.].

**Web (5):** Zasićenost boje. URL: <https://media-x.hr/zasicenost-boje-2/> [datum pristupa: 14.11.2018.].

**Web (6):** RGB prostor boja. URL: <http://www.arcsoft.com/topics/photostudio-darkroom/what-is-color-space.html> [datum pristupa: 14.11.2018.].

**Web (7):** Prikaz CIE L\*a\*b\* prostora boja. URL: [http://eprints.grf.unizg.hr/2088/1/Z513\\_Grigic\\_Emilija.pdf](http://eprints.grf.unizg.hr/2088/1/Z513_Grigic_Emilija.pdf) [datum pristupa: 14.11.2018.].

**Web (8):** Kolorimetar Konica Minolta CR-400. URL: <https://sensing.konicaminolta.us/products/cr-400-chroma-meter-colorimeter/> [datum pristupa: 14.11.2018.].

**Web (9):** *Skener EPSON Perfection V500 Photo*. URL:

<https://www.epson.hr/products/scanners/consumer-scanners/epson-perfection-v500-photo> [datum pristupa: 14.11.2018.].

**Web (10):** Koceva Komlenić D, Jukić M: Materijali s predavanja na kolegiju „Tehnologija proizvodnje tjestenine i keksarskih proizvoda“. Prehrambeno-tehnološki fakultet Osijek, Osijek, 2018.

URL:[http://studenti.ptfos.hr/Diplomski\\_studij/Tjestenicarstvo\\_Keksarstvo/Keks\\_2\\_2017\\_18.pdf](http://studenti.ptfos.hr/Diplomski_studij/Tjestenicarstvo_Keksarstvo/Keks_2_2017_18.pdf) [datum pristupa: 14.11.2018.].

**Yam KL, Papadakis SE:** A simple digital imaging method for measuring and analyzing color of food surfaces. *Journal of Food Engineering*. 61:137–142, 2004.